

智能大数据与深度学习

朱定局 著

電子工業出版社

Publishing House of Electronics Industry

北京 · BEIJING

内 容 简 介

本书是一本原创性的学术专著，分为两部分，第一部分介绍智能大数据与深度学习的理论方法；第二部分介绍智能大数据与深度学习的应用实践。本书的原创性在于提出、研究并给出了 12 种智能大数据与深度学习的新理论、新方法和新应用。

本书可作为高等院校、科研院所和企事业单位的科研及教学用书。

未经许可，不得以任何方式复制或抄袭本书之部分或全部内容。

版权所有，侵权必究。

图书在版编目 (CIP) 数据

智能大数据与深度学习 / 朱定局著. —北京：电子工业出版社，2018.10

ISBN 978-7-121-34286-8

I. ①智… II. ①朱… III. ①数据处理—高等学校—教材 IV. ①TP274

中国版本图书馆 CIP 数据核字 (2018) 第 111033 号

策划编辑：刘 瑀

责任编辑：章海涛

印 刷：

装 订：

出版发行：电子工业出版社

北京市海淀区万寿路 173 信箱 邮编：100036

开 本：720×1000 1/16 印张：12.5 字数：160 千字

版 次：2018 年 10 月第 1 版

印 次：2018 年 10 月第 1 次印刷

定 价：69.00 元

凡所购买电子工业出版社图书有缺损问题，请向购买书店调换。若书店售缺，请与本社发行部联系，联系及邮购电话：(010)88254888，88258888。

质量投诉请发邮件至 zltz@phei.com.cn，盗版侵权举报请发邮件至 dbqq@phei.com.cn。

本书咨询联系方式：liuy01@phei.com.cn。

前 言

因为 AlphaGo 战胜了人类围棋冠军，深度学习一举成名，再加上 BAT、谷歌等国内外知名公司的推崇，深度学习的热浪一波高过一波。深度学习之所以能使神经网络重新受到学者的青睐，主要是因为它用非监督式或半监督式的特征学习和分层特征提取高效算法，替代了手工获取特征，从而使过去被废弃的大量非标签数据得到利用。更重要的是，这也使深度学习的深度得到了极大增加，从而提高了深度学习的处理能力。深度学习虽然是一个初生儿，但地位极高，因为其前身是具有悠久历史的神经网络。20 年前，在我上大学期间，就有神经网络的课程。由于深度学习发展时间较短，所以不论在理论上还是在应用上，它都存在很多盲点和缺陷，都需要开拓、创新、完善和升级。

深度学习的春雨过后，无人驾驶、图像识别等人工智能相关应用，如雨后春笋般层出不穷。随着应用的深度发展，其理论研究也在如火如荼地进行。很多企业和高校已经成立了深度学习的研究中心或小组，专门研究深度学习的相关理论和应用，同时，深度学习的培训课程也在国内外掀起了热潮，但其困境是，关于深度学习理论和应用的相关著作仍然比较缺乏。

在深度学习之前，大数据已经火热了几年，深度学习的出现为大数据智能处理提供了一个新的出路。深度学习只有基于大数据才能发挥威力，才能达到很高的准确度。而大数据在应用了深度学习之后，所能达到的处理效果也是传统算法无法企及的。可以说，两者相得益彰、相互促进、互利共赢。

本书可以作为学习和研究深度学习的参考用书，其中，理论部分可以用于完善现有深度学习方法的不足，为理论创新奠定基础；应用部分可以为企业提供更多深度学习应用的新思路和新方案，进而使深度学习在实践中产生更大的价值。

本书的所有章节都是作者原创性的研究成果。本书内容的原创性在于：首次提出并研究给出了两种增强型深度学习神经网络方法及应用，包括基于顶层生成深度学习的数据转换方法和系统，基于双向深度学习的数据对应关系判断、生成方法和系统；首次提出并研究给出了两种高效智能型深度学习神经网络方法及应用，包括精简输入的深度学习方法和系统，基于数据分割的深度学习方法和系统；首次提出并研究给出了两种动态智能型深度学习神经网络方法及应用，包括基于有向图的深度学习构建方法和系统，深度学习神经网络训练方法及层数调整方法和系统；首次提出并研究给出了两种深度学习的大数据智能计算应用，包括基于大数据与深度学习的信息隐藏、提取方法和系统，基于大数据与深度学习的婚恋对象匹配数据处理方法和系统；首次提出并研究给出了两种深度学习的大数据智能诊断应用，包括基于深度学习的面向自动诊断的医疗数据处理方法和系统，基于双深度学习的数据处理方法和疾病诊断装置；首次提出并研究给出了两种深度学习的大数据智能预测应用，包括基于大数据与深度学习的气象预报方法和系统，基于大数据与深度学习的用户数据处理方法和系统。

本书选取的是人工智能的前沿领域和热点领域——深度学习，并将其与各个应用领域进行了交叉创新。在交叉创新的过程中，发现和改进了现有深度学习理论的不足，同时拓展了现有深度学习应用的范围，进而实现了深度学习技术从理论到应用的创新。

本书的特色在于，以深度学习应用牵引深度学习理论的创新，同时以深度学习理论的创新促进深度学习应用的创新。本书在深度学习与各行各业之

间进行了大胆的交叉创新,从而使深度学习技术更智能、更普适、更精准、更强大,加速深度学习智能应用的发展。当然,深入后必能浅出,读者也能通过本书,学习到深度学习的新理论和新应用,加深对现有深度学习技术的理解。

书中所述的研究得到了国家级新工科研究与实践项目(粤教高函〔2018〕17号)、国家社会科学基金重大项目(14ZDB101)、国家自然科学基金重点项目(41630635)、教育部-腾讯公司产学合作协同育人项目(201602001001)、广东高校重大科研项目(粤教科函〔2018〕64)、广东省新工科研究与实践项目(粤教高函〔2017〕118号)、广东省高等教育教学研究和改革重点项目(粤教高函〔2016〕236号)、广东省学位与研究生教育改革研究重点项目(粤教研函〔2016〕39号)、广东省联合培养研究生示范基地(粤教研函〔2016〕39号)的支持。

华南师范大学

朱定局

目 录

第一部分 理 论 方 法

第 1 章	增强型深度学习神经网络	2
1.1	基于顶层生成深度学习的数据转换方法和系统	2
1.1.1	研究现状	3
1.1.2	基于顶层生成深度学习的数据转换方法	4
1.1.3	基于顶层生成深度学习的数据转换系统	7
1.2	基于双向深度学习的数据对应关系判断、生成方法和系统	9
1.2.1	研究现状	10
1.2.2	基于双向深度学习的数据对应关系判断、生成方法	11
1.2.3	基于双向深度学习的数据对应关系判断、生成系统	28
第 2 章	高效智能型深度学习神经网络	37
2.1	精简输入的深度学习方法和系统	37
2.1.1	研究现状	37
2.1.2	精简输入的深度学习方法	38
2.1.3	精简输入的深度学习系统	48
2.2	基于数据分割的深度学习方法和系统	50
2.2.1	研究现状	50

2.2.2	基于数据分割的深度学习方法	51
2.2.3	基于数据分割的深度学习系统	57
第 3 章	动态智能型深度学习神经网络	60
3.1	基于有向图的深度学习构建方法和系统	60
3.1.1	研究现状	60
3.1.2	基于有向图的深度学习构建方法	61
3.1.3	基于有向图的深度学习构建系统	70
3.2	深度学习神经网络训练及层数调整方法和系统	72
3.2.1	研究现状	72
3.2.2	深度学习神经网络训练及层数调整方法	74
3.2.3	深度学习神经网络训练及层数调整系统	80

第二部分 应用实践

第 4 章	深度学习的大数据智能计算应用	86
4.1	基于大数据与深度学习的信息隐藏、提取方法和系统	86
4.1.1	研究现状	86
4.1.2	基于大数据与深度学习的信息隐藏、提取方法	89
4.1.3	基于大数据与深度学习的信息隐藏、提取系统	102
4.2	基于大数据与深度学习的婚恋对象匹配数据处理方法和系统	108
4.2.1	研究现状	108
4.2.2	基于大数据与深度学习的婚恋对象匹配数据处理方法	109
4.2.3	基于大数据与深度学习的婚恋对象匹配数据处理系统	120
第 5 章	深度学习的大数据智能诊断应用	123
5.1	基于深度学习的面向自动诊断的医疗数据处理方法和系统	123

5.1.1	研究现状	124
5.1.2	基于深度学习的面向自动诊断的医疗数据处理方法	124
5.1.3	基于深度学习的面向自动诊断的医疗数据处理系统	126
5.2	基于双深度学习的数据处理方法和疾病诊断装置	132
5.2.1	研究现状	132
5.2.2	基于双深度学习的数据处理方法	133
5.2.3	基于双深度学习的疾病诊断装置	145
第 6 章	深度学习的大数据智能预测应用	148
6.1	基于大数据与深度学习的气象预报方法和系统	148
6.1.1	研究现状	148
6.1.2	基于大数据与深度学习的气象预报方法	149
6.1.3	基于大数据与深度学习的气象预报系统	155
6.2	基于大数据与深度学习的用户数据处理方法和系统	157
6.2.1	研究现状	157
6.2.2	基于大数据与深度学习的用户数据处理方法	158
6.2.3	基于大数据与深度学习的用户数据处理系统	175
结束语		181
参考文献		182

The background features a large, wavy, dotted pattern that resembles a stylized wave or a textured surface. A sphere, also covered in the same dotted pattern, is positioned in the lower right quadrant, casting a soft shadow on the surface below it.

第一部分 理论方法

第 1 章 增强型深度学习神经网络

本章提出的增强型深度学习神经网络将现有技术中深度学习的功能进行了增强，能够实现更为强大的功能。本章给出了两种增强型深度学习神经网络及其应用，包括基于顶层生成深度学习的数据转换方法和系统，基于双向深度学习的数据对应关系判断、生成方法和系统。

1.1 基于顶层生成深度学习的数据转换方法和系统

本节研究了一种基于顶层生成深度学习的数据转换方法和系统，所述方法包括：① 建立深度学习神经网络，学习目标分辨率的样本数据；② 将源分辨率数据转换为第一目标分辨率数据；③ 将第一目标分辨率数据作为深度学习神经网络的输入，通过深度学习的认知过程得到深度学习神经网络的顶层概念；④ 通过深度学习将第一目标分辨率数据获取到顶层概念中，并生成第二目标分辨率数据，将第二目标分辨率数据作为源分辨率数据的转换结果。

本节所述的内容能够满足数据转换时对数据细节一致性的需求，便于人们查看数据的细节或全貌，有利于计算机更精细化、更节省资源地处理数据。

1.1.1 研究现状

在研究中，人们采集的数据分辨率往往受环境和采集设备的影响而不能满足需求，例如，照片由于雾霾、光线、摄像机分辨率等因素而分辨率不高，扫描出来的图片由于扫描仪的分辨率限制而分辨率不够。这些情况下，提高数据的分辨率至关重要。现有的提高数据分辨率的方法是插值或拟合，插值或拟合一般是指对相邻的已知数据值进行加权平均，得到需要插入的未知数据值。但实际上数据的分布并不是固定的，而是变化的，插值或拟合的方法只能采用固定的插值或拟合公式，因此，以固定的方式对分布变化的数据进行插值或拟合显然会在提高分辨率的同时造成数据的失真^[1-10]。

另外，从高分辨率到低分辨率，现有技术往往通过删除一些数据来实现，可能会导致得到的低分辨率数据不连贯。一种方式是通过高分辨率数据加权平均统计或拟合得到低分辨率数据，但实际上数据的分布并不是固定的，而是变化的，统计或拟合的方式只能采用固定的统计或拟合公式，因此，以固定的方式对分布变化的数据进行统计或拟合显然会在降低分辨率的同时造成数据的失真。

我们知道，人类往往能根据低分辨率的数据想象出高分辨率的数据，也能根据高分辨率的数据想象出低分辨率的数据。深度学习类似人的大脑，是从神经网络技术发展而来的。

现有的深度学习技术能通过输入数据得到输出标签（例如，输入头像输出身份证号，输入语音输出身份证号），但在自顶向下的监督训练阶段，需要通过带标签的数据（例如，带有身份证号标签的头像或带有身份证号标签的语音）进行监督训练^[11-17]。但是，现有深度学习技术无法通过输入一类数据得到另一类过于复杂的标签数据输出，因为只有比较简单的标签数据（如

类别标签)才能用于现有的深度学习技术,过于复杂的标签数据输出会使深度学习的计算复杂度剧增,无法在有效的时间内完成计算。因此,过于复杂的标签数据无法作为现有深度学习神经网络的输出。也就是说,通过现有深度学习技术不可能实现输入低分辨率数据得到高分辨率数据,或输入高分辨率数据得到低分辨率数据。同时,深度学习的认知过程只能认知出输入数据的特征,而无法从输入数据中认知出比输入数据更高或更低分辨率的数据,所以,通过深度学习的认知过程也无法实现从低分辨率数据得到高分辨率数据,或从高分辨率数据得到低分辨率数据。

为了解决上述技术的缺陷,本书提供了一种基于顶层生成深度学习的数据转换方法,该方法相对于现有技术具有如下优势。

在学习阶段,通过高(低)分辨率样本数据对应的低(高)分辨率样本数据,学习和训练出能够认知出低(高)分辨率样本数据顶层概念的深度学习神经网络。在应用阶段,将待转换的高(低)分辨率数据转换为第一低(高)分辨率数据,然后将第一低(高)分辨率数据作为深度学习神经网络的输入,得到深度学习的顶层概念,再通过深度学习的顶层概念,由深度学习神经网络生成第二低(高)分辨率数据,并将第二低(高)分辨率数据作为给定的待转换的高(低)分辨率数据的转换结果。满足了高(低)分辨率数据转换为低(高)分辨率数据时对数据细节一致性的需求。

1.1.2 基于顶层生成深度学习的数据转换方法

基于顶层生成深度学习的数据转换方法可将照片、遥感图像、语音、点云数据等数据的分辨率提高或降低,便于人们查看数据细节或全貌,有利于计算机更精细化、更节省资源地进行处理。

如图 1-1 所示,本技术方案提供了一种基于顶层生成深度学习的数据转换方法。

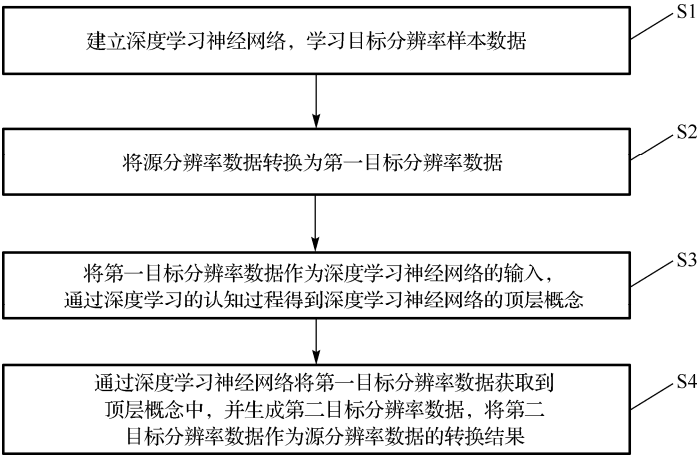


图 1-1 基于顶层生成深度学习的数据转换方法流程图

该方法包括以下步骤。

(1) 步骤 S1：建立深度学习神经网络，学习目标分辨率样本数据。具体实现步骤如图 1-2 所示。

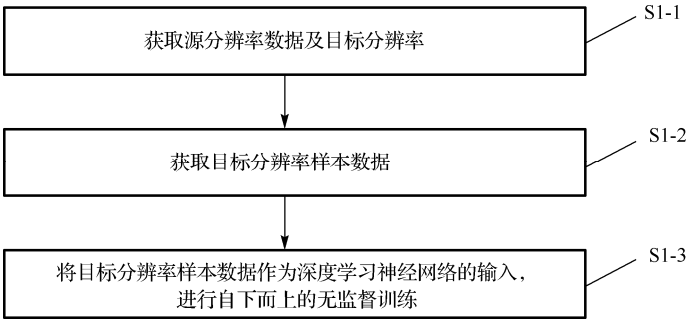


图 1-2 建立深度学习神经网络流程图

① 步骤 S1-1：获取源分辨率数据及目标分辨率。例如，源分辨率是预设的低分辨率，输入数据是猪头像，目标分辨率是预设的高分辨率。

② 步骤 S1-2：获取目标分辨率样本数据。目标分辨率样本数据需与源分辨率数据的类别相同。例如，源分辨率是预设的低分辨率，输入数据是猪头像，目标分辨率是预设的高分辨率，也需要用猪头像样本学习，而不能用

狗头像样本来学习。因此，目标分辨率样本数据应是猪头像。

③ 步骤 S1-3：将目标分辨率样本数据作为深度学习神经网络的输入，进行自下而上的无监督训练。例如，将预设的高分辨率的每个猪头像作为深度学习神经网络的输入。

(2) 步骤 S2：将源分辨率数据转换为第一目标分辨率数据。

本技术方案采用现有的插值、拟合技术将源分辨率数据转换为第一目标分辨率数据，也可以采用其他类似的技术，第一目标分辨率数据记为第一数据。

例如，将预设的低分辨率的猪头像转换为第一预设高分辨率数据。

(3) 步骤 S3：将第一目标分辨率数据作为深度学习神经网络的输入，通过深度学习的认知过程得到深度学习神经网络的顶层概念。

例如，将第一预设高分辨率数据作为深度学习神经网络的输入，通过深度学习的认知过程得到深度学习神经网络的顶层概念。

具体地，通过深度学习的认知过程得到深度学习神经网络的顶层概念，包括：

① 通过下层的概念和向上的认知 (Encoder) 权重产生上层的概念，上层概念比下层概念更抽象，最下层的概念是输入数据，最上层的概念是顶层概念。

② 首先从输入数据认知得到隐层第一层的概念，然后由隐层第一层的概念认知得到隐层第二层的概念，以此类推，直到得到隐层最后一层的概念，将隐层最后一层的概念作为深度学习神经网络的顶层概念。

(4) 步骤 S4：通过深度学习神经网络将第一目标分辨率数据获取到顶层概念中，并生成第二目标分辨率数据，将第二目标分辨率数据作为源分辨率数据的转换结果。

例如，通过深度学习神经网络将第一预设高分辨率数据获取到顶层概念

中,并生成第二预设高分辨率数据,将第二预设高分辨率数据作为源分辨率数据的转换结果。

具体地,通过深度学习神经网络生成第二目标分辨率数据,包括:

① 通过上层的概念和向下的生成(Decoder)权重产生下层的概念,下层概念比上层概念更具体,最上层的概念是顶层概念,最下层的概念是输入数据。

② 首先从顶层概念(隐层最后一层)生成得到隐层倒数第二层的概念,然后由隐层倒数第二层的概念认知得到隐层倒数第三层的概念,以此类推,直到得到输入层的概念,将输入层的概念作为第二目标分辨率数据。

可以理解的是,由于这个深度学习神经网络已经学习过很多未失真、无缺陷的目标分辨率样本数据,因此已具备了根据顶层概念生成逼真目标分辨率数据的能力。第一目标分辨率数据是采用现有技术转换成的,虽然有失真,但其中主要特征未变,可以被深度学习神经网络获取到顶层概念中,再由深度学习神经网络生成(如同人的想象)逼真的第二目标分辨率数据,这个逼真的第二目标分辨率数据即作为待转换的源分辨率数据的转换结果。这样就可以将低分辨率图像生成逼真的高分辨率图像了。

同样地,源分辨率也可以是预设的高分辨率,此时目标分辨率是预设的低分辨率。

1.1.3 基于顶层生成深度学习的数据转换系统

如图 1-3 所示,本技术方案提供了一种基于顶层生成深度学习的数据转换系统,所述系统包括深度学习神经网络建立模块 1、数据转换模块 2、顶层概念获取模块 3 和数据生成模块 4,各个模块的具体功能如下。

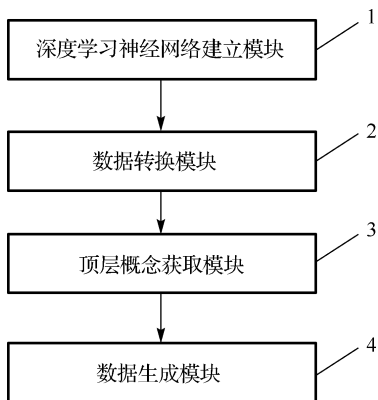


图 1-3 数据转换系统的结构图

1. 深度学习神经网络建立模块

深度学习神经网络建立模块用于建立深度学习神经网络，学习目标分辨率样本数据，如图 1-4 所示。具体包括：

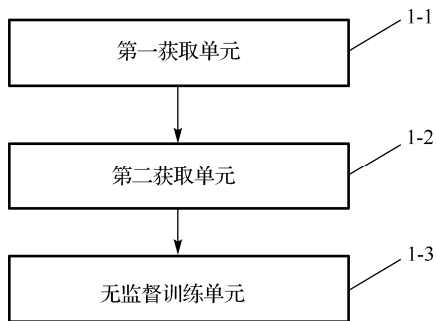


图 1-4 深度学习神经网络建立模块的结构图

- ① 第一获取单元 1-1，用于获取源分辨率数据及目标分辨率。
- ② 第二获取单元 1-2，用于获取目标分辨率样本数据；其中，目标分辨率样本数据与源分辨率数据的类别相同。
- ③ 无监督训练单元 1-3，用于将目标分辨率样本数据作为深度学习神经网络的输入，进行自下而上的无监督训练。

2. 数据转换模块

数据转换模块用于将源分辨率数据转换为第一目标分辨率数据。

3. 顶层概念获取模块

顶层概念获取模块用于将第一目标分辨率数据作为深度学习神经网络的输入,通过深度学习的认知过程得到深度学习神经网络的顶层概念。其中,所述通过深度学习的认知过程得到深度学习神经网络的顶层概念,具体包括:根据第一目标分辨率数据认知得到隐层第一层的概念,根据隐层第一层的概念认知得到隐层第二层的概念,以此类推,直到得到隐层最后一层的概念,将隐层最后一层的概念作为深度学习神经网络的顶层概念。

4. 数据生成模块

数据生成模块用于通过深度学习神经网络将第一目标分辨率数据获取到顶层概念中,并生成第二目标分辨率数据,作为源分辨率数据的转换结果。其中,所述通过深度学习神经网络生成的第二目标分辨率数据,具体包括:从顶层概念生成得到隐层倒数第二层的概念,根据隐层倒数第二层的概念认知得到隐层倒数第三层的概念,以此类推,直到得到输入层的概念,将输入层的概念作为第二目标分辨率数据。

1.2 基于双向深度学习的数据对应关系判断、生成方法和系统

本节研究了一种基于双向深度学习的数据对应关系判断、生成方法和系统。所述数据对应关系判断方法包括:① 建立双向深度学习神经网络,学

习两类输入数据之间的预设对应关系；② 利用建立的双向深度学习神经网络判断两类测试输入数据之间是否具备预设对应关系。所述数据对应关系生成方法包括：① 建立双向深度学习神经网络，学习两类输入数据之间的预设对应关系；② 利用建立的双向深度学习神经网络，根据一类输入数据生成另一类输入数据。所述数据对应关系判断系统包括：第一双向深度学习神经网络建立模块和数据对应关系判断模块；所述数据对应关系生成系统包括：第二双向深度学习神经网络建立模块和数据生成模块。

1.2.1 研究现状

现有的深度学习技术能通过输入数据得到输出标签(例如，输入头像输出身份证号，输入语音输出身份证号)，但在自顶向下的监督训练阶段必须通过带标签的数据进行监督训练(例如，带有身份证号标签的头像或带有身份证号标签的语音)^[11-17]。

如果同时具备带有身份证号标签的头像和带有身份证号标签的语音，则可以通过深度学习神经网络分别得到一个头像对应的身份证号和一个语音对应的身份证号，然后判断这两个身份证号是否相同。如果相同，则判断所述头像与语音对应的是同一人；如果不同，则判断所述头像与语音对应的不是同一人。但是，如果不同时具备带有身份证号标签的头像和带有身份证号标签的语音，则无法判断所述头像与语音对应的是否是同一人。因为没有标签，所以无法进行深度学习。

如果不用深度学习神经网络的输出标签层，由于不同类型的输入数据通过深度学习认知出来的是不同类型的特征，而不同类型特征之间无法实现匹配和转换(例如，图像特征和声音特征之间是无法实现匹配和转换的)，因此，如果只有头像和语音及部分头像和语音之间的对应关系(对应同一人)，则通

过现有的深度学习技术，无法判断所述头像与语音对应的是否是同一人，也无法根据头像得到语音或根据语音得到图像。

如果同时具备带有身份证号标签的头像和带有身份证号标签的语音，则可以通过深度学习神经网络分别得到一个头像对应的身份证号和该身份证号对应的语音，从而得到该图像对应的语音。但是，如果不同时具备带有这两者，则没有标签，无法完成深度学习。

本书提供了一种基于双向深度学习的数据对应关系判断方法和一种基于双向深度学习的数据生成方法。所述方法相对于现有技术具有如下优势。

(1) 数据对应关系判断方法可以通过双向深度学习神经网络来建立两类输入数据之间的预设对应关系，进而判断两类测试输入数据是否存在对应关系。例如，通过双向深度学习神经网络来建立头像数据与语音数据之间的对应关系(对应同一人)，进行可以判断头像数据中的某一头像与语音数据中某一音频是否对应同一人。

(2) 数据生成方法可以通过双向深度学习神经网络来建立两类输入数据之间的预设对应关系，进而可以根据一类输入数据生成另一类输入数据。例如，通过双向深度学习神经网络来建立头像数据与语音数据之间的对应关系(对应同一人)，进而可以根据头像数据中的某一头像生成对应的音频或根据语音数据中某一音频生成对应的头像。

1.2.2 基于双向深度学习的数据对应关系判断、生成方法

1. 技术方案 1

判断两类输入数据之间是否有对应关系有着现实应用价值，例如，

根据视频中某人的头像和语音，判断其头像是否为本人头像，或判断其语音是否为配音，从而鉴别视频是否为伪造的或被篡改过。又如，根据不同动物的照片生成对应动物的叫声，或根据不同动物的叫声生成对应动物的照片。

如图 1-5 所示，本技术方案提供了一种基于双向深度学习的数据对应关系判断方法。




图 1-5 数据对应关系判断方法流程图

该方法包括以下步骤。

(1) 步骤 S1：建立双向深度学习神经网络，学习两类输入数据之间的预设对应关系。具体实现步骤如图 1-6 所示。

① 步骤 S1-1：获取第一类输入数据、第二类输入数据，以及具备预设对应关系的第一类输入数据与第二类输入数据。

本技术方案的第一个例子：第一类输入数据为头像，第二类输入数据为语音，具备预设对应关系为“对应同一人”，获取多个头像、多个语音、多对对应同一人的头像与语音。

本技术方案的第二个例子：第一类输入数据为低分辨率图像，第二类输入数据为高分辨率图像，具备预设对应关系为“对应同一图像”。获取多个低分辨率图像、多个高分辨率图像、多对对应同一人的低分辨率图像与高分辨率图像。

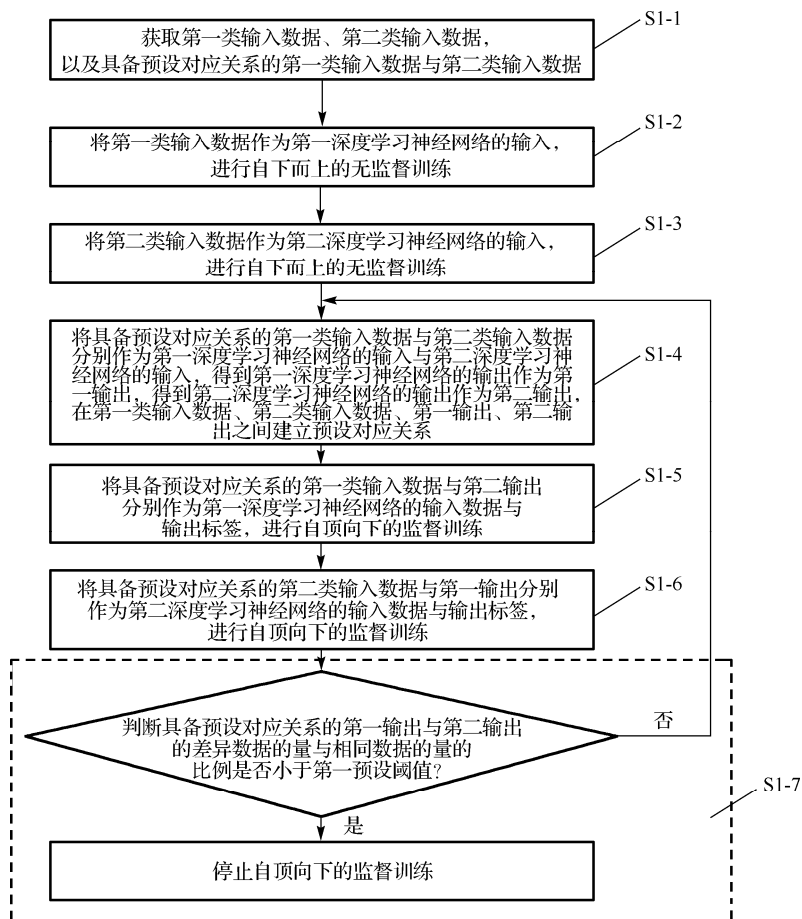


图 1-6 建立双向深度学习神经网络的流程图

② 步骤 S1-2：将第一类输入数据作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

本技术方案的第一个例子：将每个头像作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

本技术方案的第二个例子：将每个低分辨率图像作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

③ 步骤 S1-3: 将第二类输入数据作为第二深度学习神经网络的输入, 进行自下而上的无监督训练。

本技术方案的第一个例子: 将每个语音作为第二深度学习神经网络的输入, 进行自下而上的无监督训练。

本技术方案的第二个例子: 将每个高分辨率图像作为第二深度学习神经网络的输入, 进行自下而上的无监督训练。

④ 步骤 S1-4: 将具备预设对应关系的第一类输入数据与第二类输入数据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入, 得到第一深度学习神经网络的输出作为第一输出, 得到第二深度学习神经网络的输出作为第二输出, 在第一类输入数据、第二类输入数据、第一输出、第二输出之间建立预设对应关系。

本技术方案的第一个例子: 将每对对应同一人的头像与语音分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入, 得到第一深度学习神经网络的输出作为第一输出, 得到第二深度学习神经网络的输出作为第二输出, 在该头像、语音、第一输出、第二输出之间建立预设对应关系“对应同一人”。

本技术方案的第二个例子: 将每对对应同一人的低分辨率图像与高分辨率图像分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入, 得到第一深度学习的输出作为第一输出, 得到第二深度学习的输出作为第二输出, 在该低分辨率图像、高分辨率图像、第一输出、第二输出之间建立预设对应关系“对应同一图像”。

⑤ 步骤 S1-5: 将具备预设对应关系的第一类输入数据与第二输出分别作为第一深度学习神经网络的输入数据与输出标签, 进行自顶向下的监督训练。

本技术方案的第一个例子: 将每对对应同一人的头像与第二输出分别

作为第一深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

本技术方案的第二个例子：将每对对应同一图像的低分辨率图像与第二输出分别作为第一深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

⑥ 步骤 S1-6：将具备预设对应关系的第二类输入数据与第一输出分别作为第二深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

本技术方案的第一个例子：将每对对应同一人的语音与第一输出分别作为第一深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

本技术方案的第二个例子：将每对对应同一图像的低分辨率图像与第二输出分别作为第一深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

⑦ 步骤 S1-7：判断具备预设对应关系的第一输出与第二输出的差异数据的量与相同数据的量的比例是否小于第一预设阈值，若是，则停止自顶向下的监督训练；若否，则重复执行步骤 S1-4~S1-6。

本技术方案的第一个例子：判断每对对应同一人的第一输出与第二输出的差异数据的量与相同数据的量的比例是否小于第一预设阈值，若是，则停止自顶向下的监督训练；若否，则重复执行步骤 S1-4~S1-6。

本技术方案的第二个例子：判断每对对应同一图像的第一输出与第二输出的差异数据的量与相同数据的量的比例是否小于第一预设阈值，若是，则停止自顶向下的监督训练；若否，则重复执行步骤 S1-4~S1-6。

(2) 步骤 S2：利用建立的双向深度学习神经网络判断两类测试输入数据之间是否具备预设对应关系。具体步骤如图 1-7 所示。

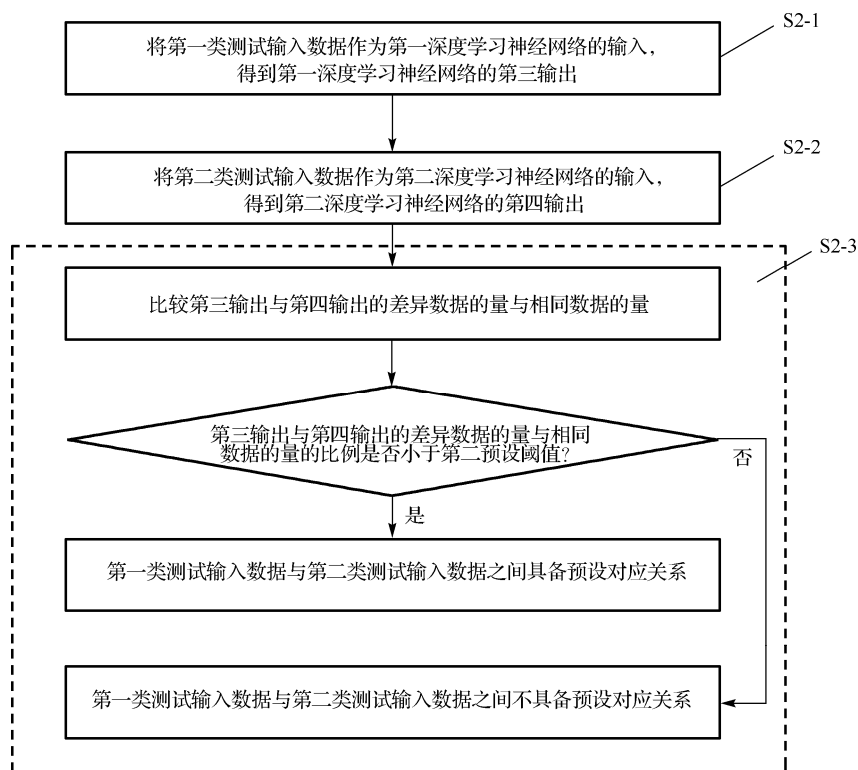


图 1-7 判断两类测试输入数据之间是否具备预设对应关系的流程图

① 步骤 S2-1：将第一类测试输入数据作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

本技术方案的第一个例子：将测试头像 P 作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

本技术方案的第二个例子：将用于测试的低分辨率图像 P 作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

② 步骤 S2-2：将第二类测试输入数据作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

本技术方案的第一个例子：将测试语音 Q 作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

本技术方案的第二个例子：将用于测试的测试高分辨率图像 Q 作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

③ 步骤 S2-3：比较第三输出与第四输出的差异数据的量与相同数据的量。

如果该第三输出与第四输出的差异数据的量与相同数据的量的比例小于第二预设阈值，则第一类测试输入数据与第二类测试输入数据之间具备预设对应关系，否则，不具备预设对应关系。

本技术方案的第一个例子：比较第三输出与第四输出的异同，如果该第三输出与第四输出的差异数据的量与相同数据的量的比例小于第二预设阈值，则图像 P 与语音 Q 对应同一人，否则对应不同人；第二预设阈值在默认情况下与第一预设阈值相同。

本技术方案的第二个例子：比较第三输出与第四输出的异同，如果该第三输出与第四输出的差异数据的量与相同数据的量的比例小于第二预设阈值，则低分辨率图像 P 与高分辨率图像 Q 对应同一图像，否则对应不同图像；第二预设阈值在默认情况下与第一预设阈值相同。

2. 技术方案 2

本技术方案提供了基于双向深度学习的数据生成方法，具有重要意义。例如，有的嫌犯(如通过电话进行诈骗的嫌犯)可能被录音了，但没有人见过其头像，如果能根据其语音生成其头像，对缉拿该嫌犯有着极为重要的作用。

如图 1-8 所示，本技术方案包括以下步骤：

(1) 步骤 S1：建立双向深度学习神经网络，学习两类输入数据之间的预设对应关系。该步骤的具体过程同技术方案 1，在此不再赘述。

(2) 步骤 S2：利用建立的双向深度学习神经网络，根据一类测试输入数据生成另一类输入数据。




图 1-8 数据生成方法的流程图

根据第一类测试输入数据生成第二类输入数据的具体实现步骤如图 1-9 所示。




图 1-9 根据第一类测试输入数据生成第二类输入数据的流程图

① 步骤 S2-1：将第一类测试输入数据作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

本技术方案的第一个例子：将测试头像作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

本技术方案的第二个例子：将用于测试的低分辨率图像作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

② 步骤 S2-2：将第三输出作为第二深度学习神经网络的输出标签，反向生成第二深度学习神经网络的第二类输入数据。

可以通过以下步骤实现：

- 从第二深度学习神经网络中匹配出所有与第二深度学习神经网络的输出标签匹配的输出标签；

- 获取匹配成功的输出标签对应的第二类输入数据，作为第二深度学习的第二类输入数据。

还可以通过以下步骤实现：

- 将顶层概念数据中所有顶层概念或部分顶层概念作为遗传算法的当前种群。
- 将当前种群中每个顶层概念作为第二深度学习中分类器的输入，通过分类器计算得到该顶层概念对应的输出标签，其中，深度学习中顶层的编解码层是一个分类器（如 Logistic 回归、SVM 等），顶层概念是最后一个隐层的输出，也是分类器的输入。
- 将每个顶层概念对应的输出标签与第二类输入数据的输出标签之间的相似度作为当前种群中每个顶层概念的适应度，其中，每个顶层概念对应的输出标签是在上一步通过深度学习神经网络中的顶层的编码层（分类器）得到的。
- 以当前种群为基础进行繁殖（包括子代突变）得到新的当前种群，回到第 1 步，重复执行，直到符合停止的预设条件为止（例如，重复执行的次数超过了预设次数或种群中适应度大于预设值的个体数超过了预设个体数）。因为当前种群中的个体是顶层概念，所以以当前种群为基础进行繁殖（包括子代突变）得到的新的个体也作为顶层概念。繁殖的过程分为三步：选择、交叉、变异。当前种群经过选择、交叉、变异运算之后得到新的当前种群。例如，顶层概念为动物图像的特征图像，从当前种群中按照适应度从大到小选择预设个数的特征图像，将选择出来的特征图像两两进行加权平均，得到新的多个特征图像，将新的多个特征图像中某些图像中的少数像素值进行求反操作，将得到的新的所有个体加入新的当前种群。

- 将最后得到的当前种群中适应度最大的顶层概念或适应度大于预设值的每个顶层概念(可能有多个)作为第二深度学习神经网络的顶层概念，生成输入数据，作为第二深度学习神经网络的第二类输入数据。

本技术方案的第一个例子：将第三输出作为第二深度学习神经网络的输出标签，反向生成第二深度学习神经网络的输入语音，作为测试头像对应的语音。

本技术方案的第二个例子：将第三输出作为第二深度学习神经网络的输出标签，反向生成第二深度学习神经网络的输入图像，作为用于测试的低分辨率图像对应的高分辨率图像。

根据第二类测试输入数据生成第一类输入数据的具体实现步骤如图 1-10 所示。




图 1-10 根据第二类测试输入数据生成第一类输入数据的流程图

① 步骤 S2-3：将第二类测试输入数据作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

本技术方案的第一个例子：将测试语音作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

本技术方案的第二个例子：将用于测试的高分辨率图像作为第二深度学习神经网络的输入，得到第二深度学习神经网络的第四输出。

② 步骤 S2-4: 将第四输出作为第一深度学习神经网络的输出标签, 反向生成第一深度学习神经网络的第一类输入数据。

本技术方案的第一个例子: 将第四输出作为第一深度学习神经网络的输出标签, 反向生成第一深度学习神经网络的输入头像, 作为测试语音对应的头像。

本技术方案的第二个例子: 将第四输出作为第一深度学习神经网络的输出标签, 反向生成第一深度学习神经网络的输入图像, 作为用于测试的高分辨率图像对应的低分辨率图像。

3. 技术方案 3

本技术方案是基于双向深度学习的数据生成方法, 总体步骤同技术方案 2, 不同之处在于步骤 S1 和 S2 的具体过程。本技术方案具有重要意义, 如提高或降低照片、遥感图像、语音、点云数据等数据的分辨率, 又如修复残缺的或有遮挡的照片、遥感图像、语音、点云数据等数据。

本技术方案的步骤 S1 如图 1-11 所示, 具体包括:

① 步骤 S1-1: 获取第一类输入数据、第二类输入数据, 以及具备预设对应关系的第一类输入数据与第二类输入数据。

本技术方案的前两个例子同技术方案 1, 在此不再赘述。

本技术方案的第三个例子: 第一类输入数据为有残缺数据; 第二类输入数据为无残缺数据; 具备预设对应关系为“对应同一数据”, 获取多个有残缺数据、多个无残缺数据、多对对应同一数据的有残缺数据与无残缺数据。

② 步骤 S1-2: 将第一类输入数据作为第一深度学习神经网络的输入, 进行自下而上的无监督训练。

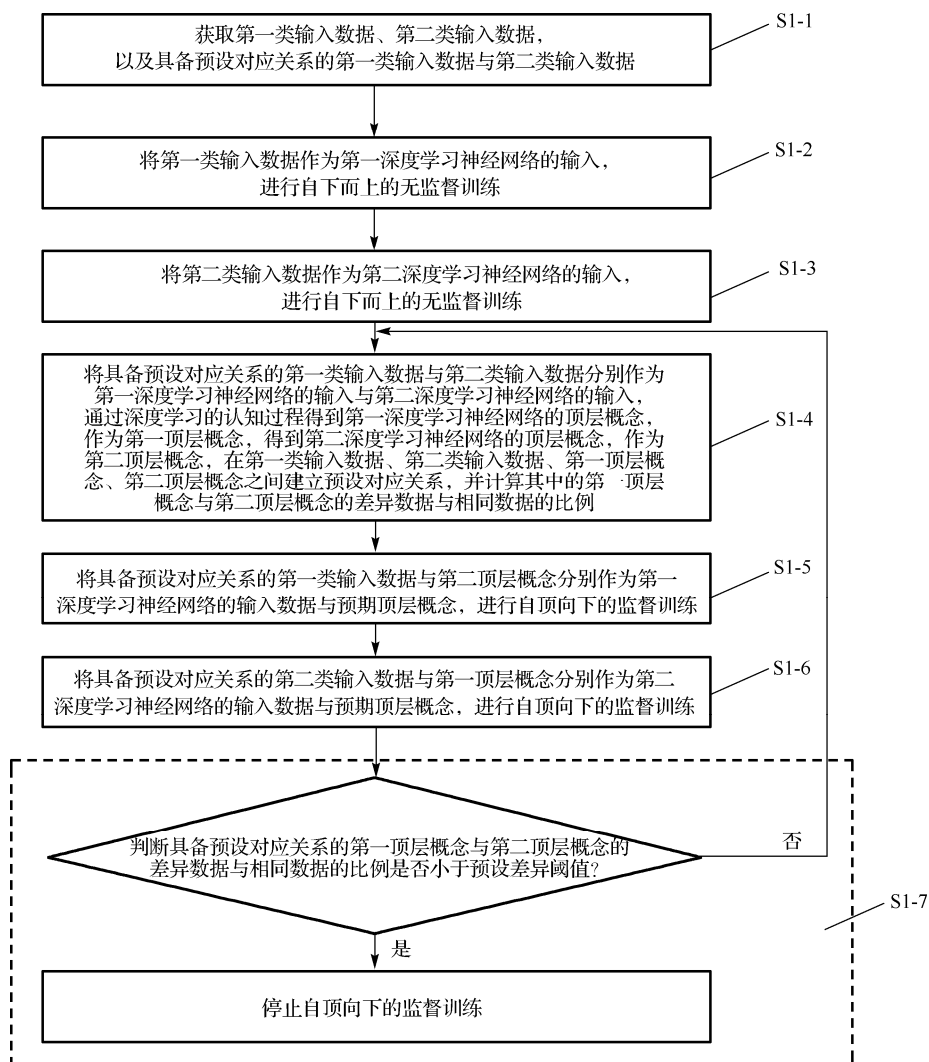


图 1-11 建立双向深度学习的流程图

本技术方案的前两个例子：同技术方案 1，在此不再赘述。

本技术方案的第三个例子：将每个有残缺数据作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

③ 步骤 S1-3：将第二类输入数据作为第二深度学习神经网络的输入，进行自下而上的无监督训练。

本技术方案的前两个例子同技术方案1，在此不再赘述。

本技术方案的第三个例子：将每个无残缺数据作为第二深度学习神经网络的输入，进行自下而上的无监督训练。

④ 步骤 S1-4：将具备预设对应关系的第一类输入数据与第二类输入数据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的顶层概念，作为第一顶层概念，得到第二深度学习神经网络的顶层概念，作为第二顶层概念，在第一类输入数据、第二类输入数据、第一顶层概念、第二顶层概念之间建立预设对应关系，并计算其中的第一顶层概念与第二顶层概念的差异数据与相同数据的比例。

本技术方案的第一个例子：将每对对应同一人的头像与语音分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的顶层概念，作为第一顶层概念，得到第二深度学习神经网络的顶层概念，作为第二顶层概念，在该头像、语音、第一顶层概念、第二顶层概念之间建立预设对应关系“对应同一人”，并计算其中的第一顶层概念与第二顶层概念的差异数据与相同数据的比例。

本技术方案的第二个例子：将每对对应同一人的低分辨率图像与高分辨率图像分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的顶层概念，作为第一顶层概念，得到第二深度学习神经网络的顶层概念，作为第二顶层概念，在该低分辨率图像、高分辨率图像、第一顶层概念、第二顶层概念之间建立预设对应关系“对应同一图像”，并计算其中的第一顶层概念与第二顶层概念的差异数据与相同数据的比例。

本技术方案的第三个例子：将每对对应同一人的有残缺数据与无残缺数

据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的顶层概念，作为第一顶层概念，得到第二深度学习神经网络的顶层概念，作为第二顶层概念，在该有残缺数据、无残缺数据、第一顶层概念、第二顶层概念之间建立预设对应关系“对应同一数据”，并计算其中的第一顶层概念与第二顶层概念的差异数据与相同数据的比例。

⑤ 步骤 S1-5：将具备预设对应关系的第一类输入数据与第二顶层概念分别作为第一深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

本技术方案的第一个例子：将每对对应同一人的头像与第二顶层概念分别作为第一深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

本技术方案的第二个例子：将每对对应同一图像的低分辨率图像与第二顶层概念分别作为第一深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

本技术方案的第三个例子：将每对对应同一数据的有残缺数据与第二顶层概念分别作为第一深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

通过输入数据与顶层概念进行监督训练的具体过程与通过输入数据与输出标签进行监督训练的过程类似，在无监督训练获得各层参数的基础上，利用梯度下降法微调整个网络参数。不同之处在于输入数据与顶层概念进行监督训练的具体过程不需要输出标签与顶层概念之间的编/解码过程。

通过一个输入数据及其对应的预期顶层概念进行监督训练的具体过程包括：

L1：通过将输入数据输入深度学习神经网络，计算得到实际顶层概念。

L2: 计算预期顶层概念与实际顶层概念之间的残差, 根据残差, 利用梯度下降法微调整个网络的参数, 调整的目标是使实际顶层概念能够更接近预期顶层概念。

L3: 重复 L1、L2, 直至预期顶层概念与实际顶层概念之间的残差小于预设残差阈值, 则通过这个输入数据及其对应的预期顶层概念进行监督训练的过程结束。

⑥ 步骤 S1-6: 将具备预设对应关系的第二类输入数据与第一顶层概念分别作为第二深度学习神经网络的输入数据与预期顶层概念, 进行自顶向下的监督训练。

本技术方案的第一个例子: 将每对对应同一人的语音与第一顶层概念分别作为第二深度学习神经网络的输入数据与预期顶层概念, 进行自顶向下的监督训练。

本技术方案的第二个例子: 将每对对应同一图像的高分辨率图像与第一顶层概念分别作为第二深度学习神经网络的输入数据与预期顶层概念, 进行自顶向下的监督训练。

本技术方案的第三个例子: 将每对对应同一数据的无残缺数据与第一顶层概念分别作为第二深度学习神经网络的输入数据与预期顶层概念, 进行自顶向下的监督训练。

⑦ 步骤 S1-7: 判断具备预设对应关系的第一顶层概念与第二顶层概念的差异数据与相同数据的比例是否小于预设差异阈值, 若是, 则停止自顶向下的监督训练; 若否, 则重复执行步骤 S1-4~S1-6。

本技术方案的步骤 S2 如图 1-12 所示, 具体包括:

① 步骤 S2-1: 将第一类测试输入数据作为第一深度学习神经网络的输入, 通过深度学习的认知过程得到第一深度学习神经网络的第三顶层概念。




图 1-12 根据第一类测试输入数据生成第二类输入数据的流程图

本技术方案的第一个例子：将测试头像作为第一深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的第三顶层概念。

本技术方案的第二个例子：将用于测试的低分辨率图像作为第一深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的第三顶层概念。

本技术方案的第三个例子：将用于测试的有残缺数据作为第一深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的第三顶层概念。

② 步骤 S2-2：将第三顶层概念作为第二深度学习神经网络的顶层概念，生成第二深度学习神经网络的第二类输入数据，作为第一类测试输入数据对应的第二类输入数据。

本技术方案的第一个例子：将第三顶层概念作为所述深度学习神经网络的顶层概念，通过深度学习的生成过程生成输入数据，作为测试头像对应的语音。

本技术方案的第二个例子：将第三顶层概念作为所述深度学习神经网络的顶层概念，通过深度学习的生成过程生成输入数据，作为测试用的低分辨率图像对应的高分辨率图像。

本技术方案的第三个例子：将第三顶层概念作为所述深度学习神经网络的顶层概念，通过深度学习的生成过程生成输入数据，作为测试用的有残缺数据对应的无残缺数据。

根据第二类测试输入数据生成第一类输入数据的具体实现步骤如图 1-13 所示。




图 1-13 根据第二类测试输入数据生成第一类输入数据的流程图

① 步骤 S2-3：将第二类测试输入数据作为第二深度学习神经网络的输入，通过深度学习的认知过程得到第二深度学习神经网络的第四顶层概念。

本技术方案的第一个例子：将测试语音作为第二深度学习神经网络的输入，通过深度学习的认知过程得到第二深度学习神经网络的第四顶层概念。

本技术方案的第二个例子：将用于测试的高分辨率图像作为第二深度学习神经网络的输入，通过深度学习的认知过程得到第二深度学习神经网络的第四顶层概念。

本技术方案的第三个例子：将用于测试的无残缺数据作为第二深度学习神经网络的输入，通过深度学习的认知过程得到第二深度学习神经网络的第四顶层概念。

② 步骤 S2-4：将第四顶层概念作为第一深度学习神经网络的顶层概念，通过深度学习的生成过程生成第一深度学习神经网络的第一类输入数据。

本技术方案的第一个例子：将第四顶层概念作为第一深度学习神经网络的顶层概念，通过深度学习的生成过程生成输入数据，作为测试语音对应的头像。

本技术方案的第二个例子：将第四顶层概念作为第一深度学习神经网络

的顶层概念，通过深度学习的生成过程生成输入数据，作为测试用的高分辨率图像对应的低分辨率图像。

本技术方案的第三个例子：将第四顶层概念作为第一深度学习神经网络的顶层概念，通过深度学习的生成过程生成输入数据，作为测试用的无残缺数据对应的有残缺数据。

可以理解的是，虽然数据类型不同，具备对应关系的第一类输入数据与第二类输入数据通过双向深度学习神经网络可以得到匹配的顶层概念，因为具备对应关系的这两类输入数据只是类不同，从而细节不同，但其关键特征是一致的，因此其顶层概念是有可能达成一致的。所以，通过双向监督训练，两种输入数据在顶层概念上进行匹配，使这种对应关系能够通过双向深度学习得以存储和表达，进而应用于具备对应关系的不同类数据之间的转换。

1.2.3 基于双向深度学习的数据对应关系判断、生成系统

1. 技术方案 4

如图 1-14 所示，本技术方案提供了一种基于双向深度学习的数据对应关系判断系统，该系统包括第一双向深度学习神经网络建立模块 1 和数据对应关系判断模块 2。




图 1-14 数据对应关系判断系统的结构图

(1) 第一双向深度学习神经网络建立模块 1

第一双向深度学习神经网络建立模块 1，用于建立双向深度学习神经网络，学习两类输入数据之间的预设对应关系，如图 1-15 所示，具体包括：

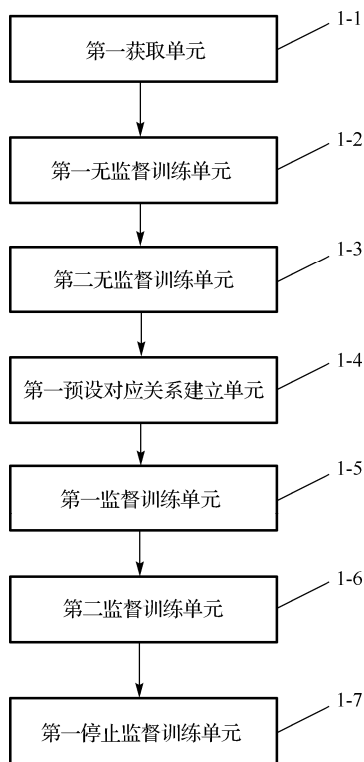


图 1-15 第一双向深度学习神经网络建立模块 1 的结构图

① 第一获取单元 1-1，用于获取第一类输入数据、第二类输入数据，以及具备预设对应关系的第一类输入数据与第二类输入数据。

② 第一无监督训练单元 1-2，用于将第一类输入数据作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

③ 第二无监督训练单元 1-3，用于将第二类输入数据作为第二深度学习神经网络的输入，进行自下而上的无监督训练。

④ 第一预设对应关系建立单元 1-4, 用于将具备预设对应关系的第一类输入数据与第二类输入数据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入, 得到第一深度学习神经网络的输出, 作为第一输出, 得到第二深度学习神经网络的输出, 作为第二输出, 在第一类输入数据、第二类输入数据、第一输出、第二输出之间建立预设对应关系。

⑤ 第一监督训练单元 1-5, 用于将具备预设对应关系的第一类输入数据与第二输出分别作为第一深度学习神经网络的输入数据与输出标签, 进行自顶向下的监督训练。

⑥ 第二监督训练单元 1-6, 用于将具备预设对应关系的第二类输入数据与第一输出分别作为第二深度学习神经网络的输入数据与输出标签, 进行自顶向下的监督训练。

⑦ 第一停止监督训练单元 1-7, 用于当具备预设对应关系的第一输出与第二输出的差异数据的量与相同数据的量的比例小于第一预设阈值时, 停止自顶向下的监督训练。

(2) 数据对应关系判断模块 2

数据对应关系判断模块 2, 用于利用建立的双向深度学习神经网络判断两类测试输入数据之间是否具备预设对应关系, 如图 1-16 所示, 具体包括:

① 第一深度学习单元 2-1, 用于将第一类测试输入数据作为第一深度学习神经网络的输入, 得到第一深度学习单元的第三输出。

② 第二深度学习单元 2-2, 用于将第二类测试输入数据作为第二深度学习神经网络的输入, 得到第二深度学习单元的第四输出。

③ 比较单元 2-3, 用于比较第三输出与第四输出的差异数据的量与相同数据的量, 如果该第三输出与第四输出的差异数据的量与相同数据的量的比

例小于第二预设阈值，则第一类测试输入数据与第二类测试输入数据之间具备预设对应关系，否则不具备预设对应关系。




图 1-16 数据对应关系判断模块 2 的结构图

2. 技术方案 5

如图 1-17 所示，本技术方案提供了一种基于双向深度学习神经网络的数据生成系统，该系统包括第二双向深度学习神经网络建立模块 3 和数据生成模块 4。




图 1-17 数据生成系统的结构图

(1) 第二双向深度学习神经网络建立模块 3

第二双向深度学习神经网络建立模块 3，用于建立双向深度学习神经网络，学习两类输入数据之间的预设对应关系，如图 1-18 所示，具体包括：

- ① 第二获取单元 3-1，用于获取第一类输入数据、第二类输入数据，以及具备预设对应关系的第一类输入数据与第二类输入数据。

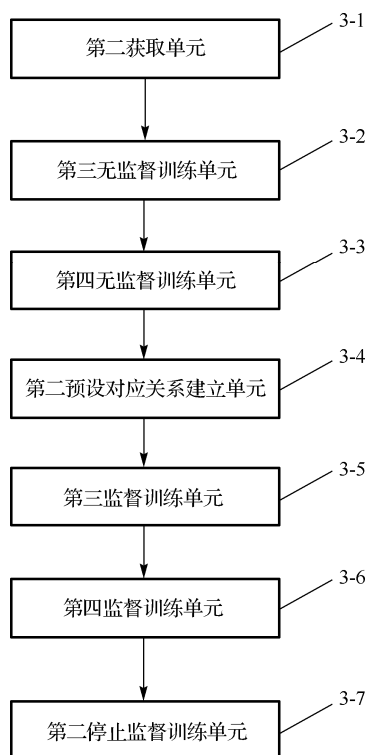


图 1-18 第二双向深度学习神经网络建立模块 3 的结构图

② 第三无监督训练单元 3-2，用于将第一类输入数据作为第一深度学习神经网络的输入，进行自下而上的无监督训练。

③ 第四无监督训练单元 3-3，用于将第二类输入数据作为第二深度学习神经网络的输入，进行自下而上的无监督训练。

④ 第二预设对应关系建立单元 3-4，用于将具备预设对应关系的第一类输入数据与第二类输入数据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，得到第一深度学习神经网络的输出作为第一输出，得到第二深度学习神经网络的输出作为第二输出，在第一类输入数据、第二类输入数据、第一输出、第二输出之间建立预设对应关系。

⑤ 第三监督训练单元 3-5，用于将具备预设对应关系的第一类输入数据

与第二输出分别作为第一深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

⑥ 第四监督训练单元 3-6，用于将具备预设对应关系的第二类输入数据与第一输出分别作为第二深度学习神经网络的输入数据与输出标签，进行自顶向下的监督训练。

⑦ 第二停止监督训练单元 3-7，用于当具备预设对应关系的第一输出与第二输出的差异数据的量与相同数据的量的比例小于第一预设阈值时，停止自顶向下的监督训练。

(2) 数据生成模块 4

数据生成模块 4，用于利用建立的双向深度学习神经网络，根据一类输入数据生成另一类输入数据，如图 1-19 所示，具体包括：




图 1-19 数据生成模块 4 其中一种生成方案的结构图

① 第三深度学习单元 4-1，用于将第一类测试输入数据作为第一深度学习神经网络的输入，得到第一深度学习神经网络的第三输出。

② 第一反向生成单元 4-2，用于将第三输出作为第二深度学习神经网络的输出标签，反向生成得到第二深度学习神经网络的第二类输入数据。

数据生成模块的另一种生成方案如图 1-20 所示，具体包括：

③ 第四深度学习单元 4-3，用于将第二类测试输入数据作为第二深度学习单元的输入，得到第二深度学习神经网络的第四输出。

④ 第二反向生成单元 4-4，用于将第四输出作为第一深度学习神经网络的输出标签，反向生成得到第一深度学习神经网络的第一类输入数据。




图 1-20 数据生成模块 4 的另一种生成方案的结构图

3. 技术方案 6

本技术方案的基于双向深度学习的数据生成系统的总体结构同技术方案 5，区别之处在于第二双向深度学习神经网络建立模块 3 和数据生成模块 4 的具体组成部分。

(1) 第二双向深度学习神经网络建立模块 3

本技术方案的第二双向深度学习神经网络建立模块 3 如图 1-21 所示，具体包括：

- ① 第三获取单元 3-1，同技术方案 5 第二获取单元。
- ② 第五无监督训练单元 3-2，同技术方案 5 第三无监督训练单元。
- ③ 第六无监督训练单元 3-3，同技术方案 5 第四无监督训练单元。
- ④ 第三预设对应关系建立单元 3-4，用于将具备预设对应关系的第一类输入数据与第二类输入数据分别作为第一深度学习神经网络的输入与第二深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的顶层概念作为第一顶层概念，通过深度学习的认知过程得到第二深度学习单元的顶层概念作为第二顶层概念，在第一类输入数据、第二类输入数据、第一顶层概念、第二顶层概念之间建立预设对应关系，并计算其中的第一顶层概念与第二顶层概念的差异数据与相同数据的比例。

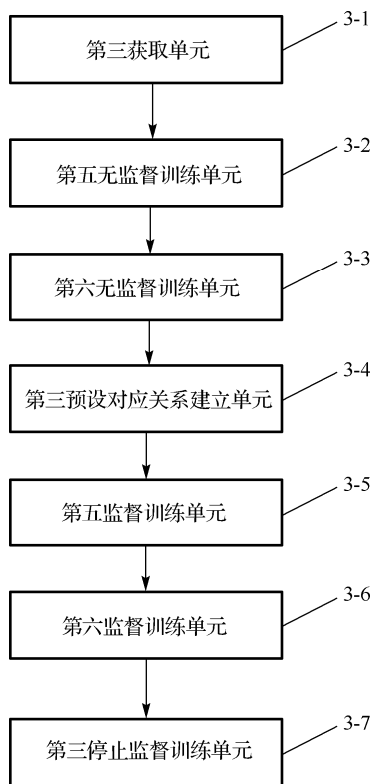


图 1-21 双向深度学习建立模块 3 的结构图

⑤ 第五监督训练单元 3-5，用于将具备预设对应关系的第一类输入数据与第二顶层概念分别作为第一深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

⑥ 第六监督训练单元 3-6，用于将具备预设对应关系的第二类输入数据与第一顶层概念分别作为第二深度学习神经网络的输入数据与预期顶层概念，进行自顶向下的监督训练。

⑦ 第三停止监督训练单元 3-7，用于当具备预设对应关系的第一顶层概念与第二顶层概念的差异数据与相同数据的比例小于预设差异阈值时，停止自顶向下的监督训练。

(4) 数据生成模块 4

本技术方案的数据生成模块 4 如图 1-22 所示，具体包括：




图 1-22 数据生成模块 4 其中一种生成方案的结构图

① 第一深度学习认知单元 4-1，用于将第一类测试输入数据作为第一深度学习神经网络的输入，通过深度学习的认知过程得到第一深度学习神经网络的第三顶层概念。

② 第一生成单元 4-2，将第三顶层概念作为第二深度学习神经网络的顶层概念，生成得到第二深度学习神经网络的第二类输入数据，作为第一类测试输入数据对应的第二类输入数据。

数据生成模块的另一种生成方案的数据生成模块如图 1-23 所示，具体包括：




图 1-23 数据生成模块 4 另一种生成方案的结构图

① 第二深度学习认知单元 4-3，用于将第二类测试输入数据作为第二深度学习神经网络的输入，认知得到第二深度学习神经网络的第四顶层概念。

② 第二生成单元 4-4，用于将第四顶层概念作为第一深度学习神经网络的顶层概念，生成得到第一深度学习神经网络的第一类输入数据。

第2章 高效智能型深度学习神经网络

现有技术中，深度学习的计算复杂度非常高，导致了实效性差、计算成本高等问题。本章研究如何在不影响深度学习效果的前提下提高时效性并降低成本。本章给出了两种高效智能型深度学习神经网络及其应用：精简输入的深度学习方法和系统与基于数据分割的深度学习方法和系统。

2.1 精简输入的深度学习方法和系统

2.1.1 研究现状

很多领域的数据采集成本高，例如医疗领域^[18-19]。传统技术中，因为缺乏对必要输入变量的确定方法，很多输入变量都是多余的。而对于深度学习，根据输入变量预测输出，有些输入变量并没有起到决定性的作用，反而增加了数据采集的成本，造成了人力、物力的浪费。

本节针对技术现状中存在的问题，提供一种能够有效避免由于输入变量冗余导致数据采集成本过高问题的精简输入的深度学习方法和系统。

上述精简输入的深度学习方法和系统，通过对第一深度学习神经网络进行测试，得到第一深度学习神经网络的第一输出正确率，再将第一深度学习神经网络的每个输入变量作为一个输入变量组合，组成尝试删除输入变量组合的集合，从这个尝试删除输入变量组合的集合中随机选取一个输入变量组

合，根据该输入变量组合得到第二深度学习神经网络，并对得到的第二深度学习神经网络进行测试，得到第二深度学习神经网络的第二输出正确率，根据得到的第一输出正确率和第二输出正确率生成可选删除输入变量组合的集合，从这些可选删除输入变量组合的集合中选取优选删除的输入变量组合，根据优选删除的输入变量组合得到第三深度学习神经网络。在最后得到的第三深度学习神经网络的输入变量中就没有很多的非必要输入变量了，因此，不需要采集过多的输入变量，大大降低了数据采集成本。

2.1.2 精简输入的深度学习方法

1. 技术方案 1

如图 2-1 所示，在本技术方案中，提供了一种精简输入的深度学习方法，具体包括：

(1) 步骤 S1：对第一深度学习神经网络进行测试，得到第一深度学习神经网络的第一输出正确率。

可以根据训练好的深度学习神经网络进行预测，但是需要对训练好的第一深度学习神经网络进行测试，才能得到第一深度学习神经网络的第一输出正确率。具体地，第一输出正确率越大，说明第一深度学习神经网络根据输入数据得到的输出标签与该输入数据对应的预期标签一致的次数越多。

在每次测试中，将输入数据输入第一深度学习神经网络，计算得到输出标签，并比较该输出标签与该输入数据对应的预期标签是否一致。将输出标签与预期标签一致的测试次数除以总测试次数，得到第一深度学习神经网络的第一输出正确率。

(2) 步骤 S2：将第一深度学习神经网络的每个输入变量作为一个输入变量组合，生成尝试删除输入变量组合的集合。

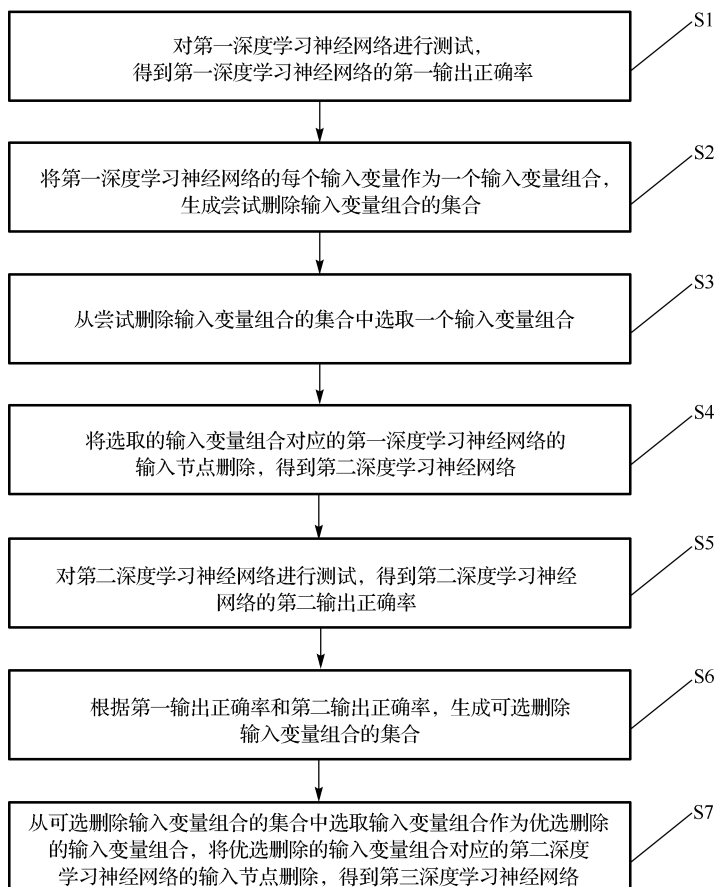


图 2-1 精简输入的深度学习方法的流程图

由于训练好的第一深度学习神经网络都设置有输入变量，因此将训练好的第一深度学习神经网络的每个输入变量作为一个组合，将所有输入变量组合生成尝试删除输入变量组合的集合。也就是说，输入变量组合是尝试删除输入变量组合的集合的子集。

(3) 步骤 S3：从尝试删除输入变量组合的集合中选取一个输入变量组合。

(4) 步骤 S4：将选取的输入变量组合对应的第一深度学习神经网络的输入节点删除，得到第二深度学习神经网络。

在尝试删除输入变量组合的集合中随机选取一个输入变量组合，将该随机选取的输入变量组合对应的第一深度学习神经网络的输入节点删除。其中，尝试删除输入变量组合的集合是指等待后面进行尝试删除输入变量组合的总集合，输入节点是指组成第一深度学习神经网络输入层的多个输入节点。也就是说，每个输入节点对应一个输入变量，如果选取的输入变量组合有多个输入变量，那么需要将这多个输入变量对应的输入节点在第一深度学习神经网络中的输入层删除，包括这个输入节点及该输入节点与其他隐层节点的所有连接，才能够得到第二深度学习神经网络。

(5) 步骤 S5：对第二深度学习神经网络进行测试，得到第二深度学习神经网络的第二输出正确率。

需要对第二深度学习神经网络进行测试，同样地，测试得到第二深度学习神经网络的第二输出正确率越大，代表第二深度学习神经网络根据输入数据计算得到的输出标签与该输入数据对应的预期标签一致的次数越多。

在每次测试中，将输入数据输入第二深度学习神经网络，计算得到输出标签，并比较该输出标签与该输入数据对应的预期标签是否一致。将输出标签与预期标签一致的测试次数除以总测试次数，得到第二深度学习神经网络的第二输出正确率。

(6) 步骤 S6：根据第一输出正确率和第二输出正确率，生成可选删除输入变量组合的集合。

在对第一深度学习神经网络进行测试得到第一输出正确率和对第二深度学习神经网络进行测试得到第二输出正确率时，会对从尝试删除输入变量组合的集合中选取的一个输入变量组合进行尝试删除，再根据第一输出正确率和第二输出正确率判断第二深度学习神经网络是否符合要求，当第二深度学习神经网络符合要求时，需要将选取的输入变量组合加入可删除输入变量组合的集合中，所以又获得了新的可删除输入变量组合的集合。但是需要将

这些可删除输入变量组合的集合中的输入变量组合加入可选删除输入变量组合中。

(7) 步骤 S7: 从可选删除输入变量组合的集合中选取输入变量组合作为优选删除的输入变量组合, 将优选删除的输入变量组合对应的第二深度学习神经网络的输入节点删除, 得到第三深度学习神经网络。

由于很多可删除输入变量组合的集合中的输入变量组合加入了可选删除输入变量组合的集合中, 所以选取一个输入变量组合作为优选删除的输入变量组合。其中, 优选删除的输入变量组合是指最值得删除的输入变量组合, 由于每个优选删除的输入变量组合中的各输入变量都有对应的输入节点, 将这些输入节点在对应的第二深度学习神经网络中的输入层删除 (包括这些输入节点及这些输入节点与其他节点的所有连接), 才能得到第三深度学习神经网络。

本技术方案中, 最后得到的第三深度学习神经网络的输入层就没有那么多非必要的输入变量了, 因此, 不需要再采集过多的输入变量来实现预测输入变量对应的标签了。

2. 技术方案 2

如图 2-2 所示, 在本技术方案中, 根据第一输出正确率和第二输出正确率生成可选删除输入变量组合的集合, 步骤 S6 包括:




图 2-2 步骤 S6 的流程图

(1) 步骤 S6-1: 根据第一输出正确率和第二输出正确率更新, 尝试删除输入变量组合的集合, 并生成可删除输入变量组合的集合。

可以根据第一输出正确率和第二输出正确率得到第二深度学习神经网络是否符合要求。如果不符合要求, 说明尝试删除选取的输入变量组合失败, 需要将这个输入变量组合从尝试删除输入变量组合的集合中删除, 防止后续重复对该输入变量组合进行测试。反之, 如果尝试删除成功了, 不仅需要将该输入变量组合从尝试删除输入变量组合的集合中删除, 而且需要将该输入变量组合加入可删除输入变量组合的集合中。

(2) 步骤 S6-2: 根据更新后的尝试删除输入变量组合的集合和可删除输入变量组合的集合, 生成可选删除输入变量组合的集合。

在对尝试删除输入变量组合的集合进行更新后, 需要对尝试删除输入变量组合的集合进行判断, 如果该集合不为空, 就说明该集合中还有输入变量组合没有进行尝试删除, 需要对这些输入变量组合继续进行尝试删除, 直到尝试删除输入变量组合的集合为空。同样地, 还需要对可删除输入变量组合的集合进行判断, 如果尝试删除输入变量组合的集合为空, 但是可删除输入变量组合的集合不为空时, 说明在测试中又获得了新的可删除输入变量组合的集合中的输入变量组合, 所以需要将这些新的可删除输入变量组合的集合中的输入变量组合加入可选删除输入变量组合的集合中, 又需要将可删除输入变量组合的集合清空, 供后续步骤使用。

本技术方案中, 通过生成尝试删除输入变量组合的集合、可删除输入变量组合的集合及可选删除输入变量组合的集合, 一次次测试将这些集合清空, 避免重复对同一个输入变量组合进行尝试删除, 同时保证最后得到的第三深度学习神经网络的输入层中没有很多非必要的输入变量。

3. 技术方案 3

如图 2-3 所示, 在本技术方案中, 根据第一输出正确率和第二输出正确率更新, 尝试删除输入变量组合的集合, 并生成可删除输入变量组合的集合, 步骤 S6-1 包括:

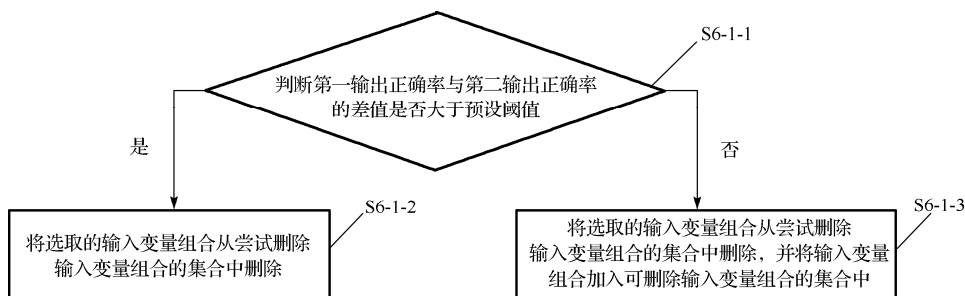


图 2-3 步骤 S6-1 的流程图

(1) 步骤 S6-1-1: 判断第一输出正确率与第二输出正确率的差值是否大于预设阈值。若是, 则进入步骤 S6-1-2; 否则进入步骤 S6-1-3。

在判断第一输出正确率与第二输出正确率的差值之前, 已经设置好预设阈值, 当第一输出正确率与第二输出正确率的差值大于预设阈值时, 第二深度学习神经网络的第二输出正确率不符合要求, 与第一深度学习神经网络的第一输出正确率的差距超过了可以容忍的预设阈值, 进入步骤 S6-1-2。反之, 如果第一输出正确率与第二输出正确率的差值小于或等于预设阈值, 则说明第二深度学习神经网络的第二输出正确率与第一深度学习神经网络的第一输出正确率的差距未超过可以容忍的预设阈值, 则进入步骤 S6-1-3。

(2) 步骤 S6-1-2: 将选取的输入变量组合从尝试删除输入变量组合的集合中删除。

当第二深度学习神经网络的第二输出正确率与第一深度学习神经网络的第一输出正确率的差距超过了预设阈值时,可以放弃之前从尝试删除输入变量组合的集合中选取的输入变量组合,尝试删除选取输入变量组合失败,需要将该输入变量组合从尝试删除输入变量组合的集合中删除,防止后面对该输入变量组合重复测试。例如,预设阈值为 5%,对第一深度学习神经网络进行测试得到的第一输出正确率为 99%,对第二深度学习神经网络进行测试得到的第二输出正确率为 92%,输入变量组合为输入变量组合 P,因为 $99\%-92\%=7\%$,大于预设阈值 5%,所以输入变量组合 P 尝试删除失败,需要将 P 从尝试删除输入变量组合的集合中删除。

(3) 步骤 S6-1-3: 将选取的输入变量组合从尝试删除输入变量组合的集合中删除,并将输入变量组合加入可删除输入变量组合的集合中。

当第二深度学习神经网络的第二输出正确率与第一深度学习神经网络的第一输出正确率的差距未超过预设阈值时,第二深度学习神经网络的第二输出正确率符合要求,之前从尝试删除输入变量组合的集合中选取的输入变量组合尝试删除成功,将尝试删除输入变量组合的集合中的输入变量组合加入可删除输入变量组合的集合中,并将该输入变量组合从尝试删除输入变量组合中删除。例如,预设阈值为 10%,对第一深度学习神经网络进行测试得到的第一输出正确率为 99%,对第二深度学习神经网络进行测试得到的第二输出正确率为 92%,输入变量组合为输入变量组合 P,因为 $99\%-92\%=7\%$,小于预设阈值 10%,所以输入变量组合 P 尝试删除成功,需要将输入变量组合 P 加入可删除输入变量组合的集合中,并且 P 从尝试删除输入变量组合的集合中删除。

4. 技术方案 4

在本技术方案中,根据更新后的尝试删除输入变量组合的集合和可删

除输入变量组合的集合，生成可选删除输入变量组合的集合，包括：判断更新后的尝试删除输入变量组合的集合是否为空。若否，则返回图 2-1 中的步骤 S3；若是，则判断更新后的可删除输入变量组合的集合是否为空，如果更新后的可删除输入变量组合的集合不为空，则将可删除输入变量组合的集合中的输入变量组合加入可选删除输入变量组合的集合中。

5. 技术方案 5

如图 2-4 所示，在本技术方案中，根据第一输出正确率和第二输出正确率生成可选删除输入变量组合的集合，步骤 S6 还包括：

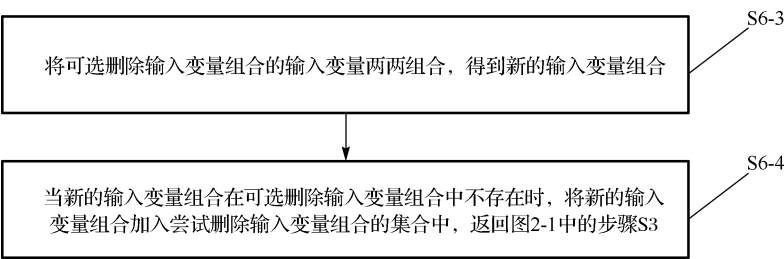


图 2-4 步骤 S6 的流程图

(1) 步骤 S6-3：将可选删除输入变量组合的输入变量两两组合，得到新的输入变量组合。

在将可删除输入变量组合的集合的所有输入变量加入可选删除输入变量组合的集合后，由于可删除输入变量组合的集合中输入变量组合的加入，可选删除输入变量组合的输入变量进行组合时会形成新的输入变量组合。

(2) 步骤 S6-4：当新的输入变量组合在可选删除输入变量组合中不存在时，将新的输入变量组合加入尝试删除输入变量组合的集合中，返回图 2-1 中的步骤 S3。

在生成新的输入变量组合之后，需要对新的输入变量组合进行判断，如果新的输入变量组合存在于可选删除输入变量组合的集合中，那么肯定

是在以前在尝试删除输入变量组合的集合中，而且并测试过，所以不需要重复测试，也就不需要再加入尝试删除输入变量组合的集合中。但是，如果新的输入变量组合不存在于可选删除输入变量组合的集合中，则需要将其加入尝试删除输入变量组合的集合中。由于这些加入尝试删除输入变量组合的集合中的新的输入变量组合还没有在第一深度学习神经网络中进行过尝试删除，所以需要返回图 2-1 中的步骤 S3。

6. 技术方案 6

在本技术方案中，对第一深度学习神经网络进行测试，得到第一深度学习神经网络的第一输出正确率，包括：获取带有预期标签的多个输入数据及其对应的预期标签；将每个输入数据作为第一深度学习神经网络的输入进行测试，得到第一实际输出标签；获取第一实际输出标签与预期标签一致的次数占总测试次数的比值，得到第一输出正确率。

本技术方案中，通过获取带有预期标签的多个输入数据及其对应的预期标签，将每个输入数据作为测试的第一深度学习神经网络的输入，得到第一实际输出标签，判断该标签与预期标签是否一致，计算第一实际输出标签与预期标签一致的次数占总测试次数的比值，得到第一深度学习神经网络的第一输出正确率。例如，有 10 000 个带有预期标签的输入数据，每次测试将每个输入数据输入第一深度学习神经网络，得到第一实际输出标签，并比较该第一实际输出标签与该输入数据对应的预期标签是否相同。统计发现，第一实际输出标签与预期标签一致的测试次数为 9900，测试总次数为 10 000，那么输入数据对应的第一实际输出标签与对应的预期标签一致的概率为 $9900/10\ 000$ ，得到第一深度学习神经网络的第一输出正确率为 99%。

7. 技术方案 7

在本技术方案中,对第二深度学习神经网络进行测试,得到第二深度学习神经网络的第二输出正确率,包括:获取带有预期标签的多个输入数据及其对应的预期标签;将每个输入数据中对应的未删除输入变量对应的数据作为第二深度学习神经网络的输入进行测试,得到第二实际输出标签;获取第二实际输出标签与所述预期标签一致的次数占总测试次数的比值,得到第二输出正确率。

本技术方案中,由于在得到第二输出正确率之前,将测试过的第一深度学习神经网络的输入变量作为一个输入组合加入尝试删除输入变量组合的集合中,在该集合中选取一个输入变量组合,将这个输入变量组合对应的第一深度学习神经网络的输入层的输入节点删除(包括与该输入节点连接的其他节点都删除),才能够得到第二深度学习神经网络,所以需要带有预期标签的多个输入数据中对应的未删除输入变量的数据作为第二深度学习神经网络的输入,得到第二实际输出数据。计算第二实际输出数据与该输入数据对应的预期标签一致的次数占总测试次数的比值,得到第二输入正确率。例如,有 10 000 个带有预期标签的多个输入数据,每次测试将每个输入数据中对应的未删除输入变量的数据输入第二深度学习神经网络,得到第二实际输出标签,并比较该第二实际输出标签与该输入数据对应的预期标签是否相同。统计发现,第二实际输出标签与预期标签一致的测试次数为 9200,测试总次数为 10 000,那么输入数据对应的第二实际输出标签与对应的预期标签一致的概率为 $9200/10\ 000$,得到第二深度学习神经网络的输出正确率为 92%。

8. 技术方案 8

在本技术方案中,从可选删除输入变量组合的集合中选取输入变量组合

作为优选删除的输入变量组合，包括：当可选删除输入变量组合的集合不为空时，从可选删除输入变量组合的集合中选取输入变量对应的数据采集成本最高的输入变量组合作为优选删除的输入变量组合。

本技术方案中，当获得的可选删除输入变量组合的集合不为空时，需要从集合中选取一个输入变量组合作为优选删除的输入变量组合，其中，优选删除的输入变量组合指的是可选删除输入变量组合的集合中的输入变量对应的数据采集成本最高的输入变量组合。在选取优选删除的输入变量组合后，得到的第三深度学习神经网络的输入变量对应的数据采集成本就能降低很多。例如，可选删除输入变量组合的集合中有多个输入变量组合：(A，B)、(A)、(B)、(C)、(D)，且各个输入变量的成本为： $A>C>D>B$ ，则成本最高的组合显然是(A、B)。

2.1.3 精简输入的深度学习系统

如图 2-5 所示，在本技术方案中，提供了一种精简输入的深度学习系统，该系统包括：

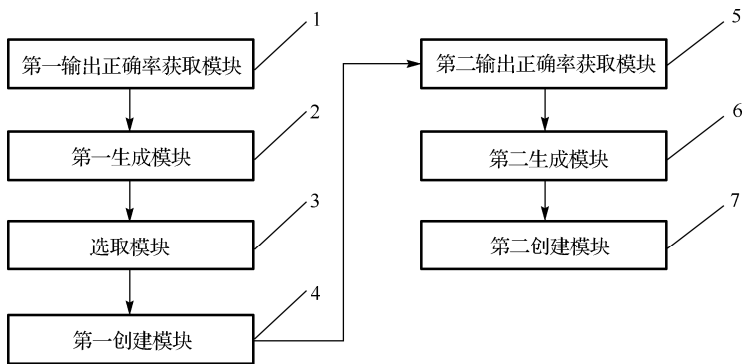


图 2-5 精简输入的深度学习系统的结构图

(1) 第一输出正确率获取模块 1，用于对第一深度学习神经网络进行测试

试，得到第一深度学习神经网络的第一输出正确率。

(2) 第一生成模块 2，用于将第一深度学习神经网络的每个输入变量作为一个输入变量组合，生成尝试删除输入变量组合的集合。

(3) 选取模块 3，用于从尝试删除输入变量组合的集合中选取一个输入变量组合。

(4) 第一创建模块 4，用于将选取的输入变量组合对应的第一深度学习神经网络的输入节点删除，得到第二深度学习神经网络。

(5) 第二输出正确率获取模块 5，用于对第二深度学习神经网络进行测试，得到第二深度学习神经网络的第二输出正确率。

(6) 第二生成模块 6，用于根据第一输出正确率和第二输出正确率生成可选删除输入变量组合的集合。

(7) 第二创建模块 7，用于从可选删除输入变量组合的集合中选取输入变量组合作为优选删除的输入变量组合，将优选删除的输入变量组合对应的第二深度学习神经网络的输入节点删除，得到第三深度学习神经网络。

在本技术方案中，第二生成模块 6 包括可删除输入变量组合生成单元、可选删除输入变量组合生成单元、组合单元和检测单元。

(1) 可删除输入变量组合生成单元，用于根据第一输出正确率和第二输出正确率更新尝试删除输入变量组合的集合，并生成可删除输入变量组合的集合。

(2) 可选删除输入变量组合生成单元，用于根据更新后的尝试删除输入变量组合的集合和可删除输入变量组合的集合，生成可选删除输入变量组合的集合。

可选删除输入变量组合生成单元还用于当第一输出正确率与第二输出正确率的差值大于预设阈值时，将选取的输入变量组合从尝试删除输入变量组合的集合中删除；反之，将选取的输入变量组合从尝试删除输入变

量组合的集合中删除,并将该输入变量组合加入可删除输入变量组合的集合中。

可选删除输入变量组合生成单元还用于判断更新后的尝试删除输入变量组合的集合是否为空。若否,则返回图 2-1 中的步骤 S3;若是,则判断更新后的可删除输入变量组合的集合是否为空,如果不为空,则将可删除输入变量组合的集合中的输入变量组合加入可选删除输入变量组合的集合中。

(3)组合单元,用于将可选删除输入变量组合的输入变量两两组合,得到新的输入变量组合。

(4)检测单元,用于当新的输入变量组合在可选删除输入变量组合中不存在时,将新的输入变量组合加入尝试删除输入变量组合的集合中,返回图 2-1 中的步骤 S3。

2.2 基于数据分割的深度学习方法和系统

2.2.1 研究现状

现有的深度学习技术在处理输入数据和输出数据非常多时,会由于计算复杂度的剧增,导致训练困难及训练得到的深度学习神经网络应用效果差^[21,22]。

本节针对技术现状中存在的问题,提供一种基于数据分割的深度学习方法和系统。通过获取待测试数据,将待测试数据按照预设多类输入变量集合分割成多个待测试子数据;将每个待测试子数据对应输入多个训练好的第一深度学习神经网络的输入层中;获取每个训练好的第一深度学习神经网络的最后隐层数据;将每个训练好的第一深度学习神经网络的最后隐层数据输入

训练好的第二深度学习神经网络的输入层中，得到训练好的第二深度学习神经网络的输出数据。

通过这种先将待测试数据按照预设多类输入变量集合分成多个子数据的方法，能够将各个子数据输入各自对应的深度学习神经网络中进行特征提取，再汇总各个深度学习神经网络的最后一个隐层的数据，将最后隐层数据均输入第二深度学习神经网络的输入变量中进行预测，通过将待测试数据分割再汇总，降低了深度学习神经网络的数据维度和计算复杂度，提高了深度学习神经网络的运算效率。

2.2.2 基于数据分割的深度学习方法

1. 技术方案 1

如图 2-6 所示，在本技术方案中，提供了一种基于数据分割的深度学习方法，具体包括：

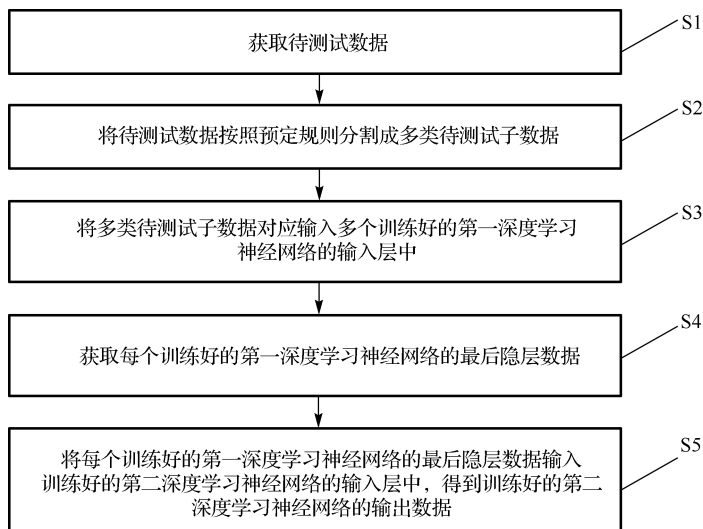


图 2-6 基于数据分割的深度学习方法的流程图

(1) 步骤 S1: 获取待测试数据。

其中, 待测试数据包括但不限于待预测数据和待分类数据。

(2) 步骤 S2: 将待测试数据按照预定规则分割成多类待测试子数据。

(3) 步骤 S3: 将多类待测试子数据对应输入多个训练好的第一深度学习神经网络的输入层中。

待测试数据可由一个或多个终端上传。当深度学习神经网络获取到待测试数据后, 会先将待测试数据按照预设多类输入变量集合分割成多类待测试子数据。例如, 获取到的待测试数据为多个时间段的数据, 预设多类输入变量集合为一个小时内, 那么当获取到多个待测试时间段的数据后, 会按照每个小时将这些数据分割。再将分割后得到的待测试子数据对应输入多个训练好的第一深度学习神经网络的输入层中。一般情况下, 第一深度学习神经网络有多个, 每个待测试子数据对应一个第一深度学习神经网络。

(4) 步骤 S4: 获取每个训练好的第一深度学习神经网络的最后隐层数据。

(5) 步骤 S5: 将每个训练好的第一深度学习神经网络的最后隐层数据输入训练好的第二深度学习神经网络的输入层中, 得到训练好的第二深度学习神经网络的输出数据。

每个深度学习神经网络中都包含输入层、隐层和输出层, 只是不同的深度学习神经网络中各个层的数量可能存在差异。输入层至少包含一个输入变量, 对于深度学习神经网络而言, 输入层的输入变量输入完毕后, 隐层会对输入变量进行特征提取与分析。因此, 第一深度学习神经网络的最后隐层数据, 已经是特征提取的峰值了。获取到每个训练好的第一深度学习神经网络的最后隐层数据后, 将每个最后隐层数据均输入训练好的第二深度学习神经网络的输入层中, 再获取训练好的第二深度学习神经网络的输出数据, 输出数据即为待测试数据的预测输出数据。

2. 技术方案2

在本技术方案中，训练好的第一深度学习神经网络与训练好的第二深度学习神经网络均包含于训练好的第三深度学习神经网络。对于第三深度学习神经网络而言，输入变量即第一深度学习神经网络的输入变量，输出数据即第二深度学习神经网络的输出数据。将数据输入第三深度学习神经网络的输入变量，实际上是将数据输入第一深度学习神经网络的输入变量中，然后将第一深度学习神经网络的最后隐层数据作为第二深度学习神经网络的输入变量，从而得到第二深度学习神经网络的输出数据，即第三深度学习神经网络的输出数据。将两个深度学习神经网络放入同一个神经网络中，无须数据转换过程，也能够提升深度学习神经网络对输入的待测试数据的预测效率。

3. 技术方案3

在本技术方案中，待测试数据为待预测数据，将待测试数据按照预设多类输入变量集合分割成多类待测试子数据。

由于待测试数据为待预测数据，因此在分割时，其实是将待预测数据按照类别分割成对应不同类别的多个待预测数据。例如，在图像处理中，获取到的待测试数据为全身照图像数据，预设多类输入变量集合为各身体部位。那么当获取到待测试全身照图像数据后，会按照身体部位将待测试的全身照图像数据分割成头部数据、上半身数据及下半身数据。

将此深度学习神经网络应用在对图像数据的处理中，并将图像数据按照身体部位进行划分，再分别输入各个身体部位对应的第一深度学习神经网络中，可对输入的身体部位数据进行精确的特征提取。这种分割数据的处理方式，能够使深度学习神经网络对数据的分析更为精准，提升了预测数据的准确性。

4. 技术方案 4

在本技术方案中，在获取待预测数据之前，还包括：获取多个训练数据；将多个图像训练数据按照预设部位类别划分标准分割成对应不同部位的多类待训练子集；为预设的每类输入变量集合初始化一个第一深度学习神经网络；从每个训练子集中分别获取训练输入数据，并输入各个训练子集对应的第一深度学习神经网络的输入层中，对每个训练子集的第一深度学习神经网络进行训练，得到多个训练好的第一深度学习神经网络。

在使用深度学习神经网络进行预测之前，需要对深度学习神经网络进行训练。图像训练数据来源于图像样本库，获取到多个图像训练数据后，会先将获取到的多个图像训练数据按照预设部位类别划分标准分割成对应不同部位的多类待训练子集。例如，将获取到的多个全身照图像数据，按照预设部分类别划分标准分割成对应不同部位的训练子数据，如头部数据、上半身数据及下半身数据。那么将全部的头部数据汇总，则组成了头部数据的子集，将全部的上半身数据汇总，则组成了上半身数据的子集，将全部的下半身数据汇总，则组成了下半身数据的子集。此处的训练子集则有三个，即头部数据的子集、上半身数据的子集及下半身数据的子集。

在将多个图像训练数据按照预设部位类别划分标准分割成对应不同部位的多类待训练子集后，为每个训练子集都初始化一个第一深度学习神经网络，再确定每个第一深度学习神经网络的输入变量和输出变量。确定了每个第一深度学习神经网络的输入变量和输出变量后，可以将训练子集中的数据分别对应输入第一深度学习神经网络的输入变量中。例如，头部数据的子集对应的第一深度学习神经网络的输入变量应为头部数据，因此头部数据子集中的数据应该输入这个与头部数据对应的第一深度学习神经网络的输入变量中。这样分别输入数据，对每个第一深度学习神经网络进行训练，则可得

到多个训练好的第一深度学习神经网络。训练后的神经网络才能用于在使用时根据输入数据预测输出数据。对深度学习神经网络进行训练能使获取到的预测结果更为准确。

5. 技术方案 5

在本技术方案中，从每个训练子集中分别获取训练输入数据，并输入各个训练子集对应的第一深度学习神经网络的输入层中，对每个训练子集的第一深度学习神经网络进行训练，得到多个训练好的第一深度学习神经网络，具体包括：从每个训练子集中分别获取训练输入数据，并输入各个训练子集对应的第一深度学习神经网络的输入层中，对每个训练子集的第一深度学习神经网络进行无监督训练。

第一深度学习神经网络的训练为无监督训练。无监督训练，简单而言，就是只有输入没有输出。因此，在对第一深度学习神经网络进行无监督训练时，会从每个训练子集中分别获取训练输入数据，并将训练输入数据对应输入各个训练子集对应的第一深度学习神经网络的输入层中。进行了无监督训练后的第一深度学习神经网络提高了特征提取能力。

6. 技术方案 6

在本技术方案中，在得到多个训练好的第一深度学习神经网络之后，步骤还包括：获取对每个训练子集的深度学习神经网络进行无监督训练时，每个训练子集的第一深度学习神经网络的最后隐层数据；将最后隐层数据输入已经初始化后的第二深度学习神经网络的输入层中，对第二深度学习神经网络进行无监督训练。将最后隐层数据输入已经初始化后的第二深度学习神经网络的输入层中，并将获取与训练输入数据对应的训练输出数据作为第二深度学习神经网络的预期输出数据，对第二深度学习神经网络进行有监督训练，得到训练好的第二深度学习神经网络。

第二深度学习神经网络在运用之前，也需要先进行针对性的训练。第二深度学习神经网络输入变量的数据来源于第一深度学习神经网络，具体是来源于第一深度学习神经网络的最后隐层数据。每个深度学习都有至少一个隐层，隐层主要用于对输入数据进行特征提取。如图 2-7 所示，第一深度学习神经网络的最后隐层数据指的是第一深度学习神经网络的最后一个隐层的数据，将每个训练子集对应的第一深度学习神经网络的最后隐层数据作为第二深度学习神经网络输入变量的输入数据，以此对第二深度学习神经网络进行训练，训练后可得到训练好的第二深度学习神经网络。在使用深度学习神经网络之前，要先对其进行训练，使其预测的结果更加准确。




图 2-7 第一深度学习神经网络的结构图

第二深度学习神经网络的训练也包括无监督训练和有监督训练。无监督训练即在将训练数据输入输入变量中时，并没有提供训练数据对应的输出数据，因此对第二深度学习神经网络进行无监督训练时，只会将第一深度学习神经网络的最后隐层数据输入第二深度学习神经网络的输入变量中，而不会提供输入变量数据对应的实际输出数据。

有监督训练与无监督训练不同，有监督训练是既有输入数据，也有输出

数据。因此在对第二深度学习神经网络进行有监督训练时，是将第一深度学习神经网络的最后隐层数据输入第二深度学习神经网络的输入变量中后，还会从每个训练子集中，将每个输入数据对应的输出数据作为第二深度学习神经网络的输出数据，以此方式对第二深度学习神经网络进行有监督训练。

对第二深度学习神经网络先进行无监督训练，再进行有监督训练后，即可得到训练好的第二深度学习神经网络。在实际运用时，训练后的第二深度学习神经网络的预测准确率和效率都会显著提高。

7. 技术方案 7

在本技术方案中，训练好的第三深度学习神经网络可由以下方式训练得到：

从每个训练子集中分别获取训练输入数据，并输入第三深度学习神经网络的输入层中，对第三深度学习神经网络进行无监督训练；从每个训练子集中分别获取训练输入数据，并输入第三深度学习神经网络的输入层中，并从每个训练子集中获取与对应的训练输出变量数据作为第三深度学习神经网络的输出数据，对第三深度学习神经网络进行有监督训练，得到训练好的第三深度学习神经网络。

2.2.3 基于数据分割的深度学习系统

如图 2-8 所示，在本技术方案中，提供了一种基于数据分割的深度学习系统的数据处理装置，装置包括：

- (1) 训练模块 1，用于训练深度学习神经网络。
- (2) 数据获取模块 2，用于获取待测试数据。
- (3) 分割模块 3，用于将待测试数据按照预设多类输入变量集合分割成多类待测试子数据。

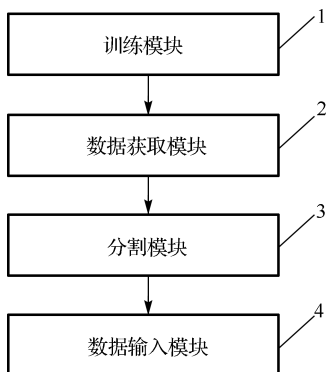


图 2-8 基于数据分割的深度学习系统的数据处理装置的结构图

(4) 数据输入模块 4，用于将多类待测试子数据对应输入多个训练好的第一深度学习神经网络的输入层中；获取每个训练好的第一深度学习神经网络的最后隐层数据；将每个训练好的第一深度学习神经网络的最后隐层数据输入训练好的第二深度学习神经网络的输入层中，得到训练好的第二深度学习神经网络的输出数据。

在本技术方案中，训练好的第一深度学习神经网络与训练好的第二深度学习神经网络包含于训练好的第三深度学习神经网络，其中，训练好的第三深度学习神经网络的输入变量为训练好的第一深度学习神经网络的输入变量，输出数据为训练好的第二深度学习神经网络的输出数据。

如图 2-9 所示，在本技术方案中，训练模块 1 包括：




图 2-9 训练模块 1 的结构图

(1) 训练数据获取模块 1-1, 用于获取多个训练数据。

(2) 训练数据分割模块 1-2, 用于将多个图像训练数据按照预设部位类别划分标准分割成对应不同部位的多类待训练子集。

(3) 初始化模块 1-3, 用于为预设的每类输入变量集合初始化一个第一深度学习神经网络。

(4) 第一训练模块 1-4, 从每个训练子集中分别获取训练输入数据, 并输入各个训练子集对应的第一深度学习神经网络的输入层中, 对每个训练子集的第一深度学习神经网络进行训练(无监督训练和有监督训练), 得到多个训练好的第一深度学习神经网络。

上述训练模块 1 还包括: 最后隐层数据获取模块, 用于获取对每个训练子集的深度学习神经网络进行无监督训练时, 每个训练子集的第一深度学习神经网络的最后隐层数据; 第二训练模块, 用于将最后隐层数据输入已经初始化后的第二深度学习神经网络的输入层中, 对第二深度学习神经网络进行无监督训练; 将最后隐层数据输入已经初始化后的第二深度学习神经网络的输入层中, 并将获取与训练输入数据对应的训练输出数据作为第二深度学习神经网络的预期输出数据, 对第二深度学习神经网络进行有监督训练, 得到训练好的第二深度学习神经网络。

上述训练模块 1 还包括第三训练模块, 用于从每个训练子集中分别获取训练输入数据, 并输入第三深度学习神经网络的输入层中, 对第三深度学习神经网络进行无监督训练; 从每个训练子集中分别获取训练输入数据, 并输入第三深度学习神经网络的输入层中, 并以与训练输入数据对应的训练输出数据作为第三深度学习神经网络的预期输出数据, 对第三深度学习神经网络进行有监督训练, 得到训练好的第三深度学习神经网络。

第3章 动态智能型深度学习神经网络

本章将现有技术中深度学习神经网络的功能进行了扩展，能够实现更为动态和复杂的功能。本章给出了两种动态智能型深度学习神经网络及其应用：基于有向图的深度学习构建方法和系统，深度学习神经网络训练方法和系统。

3.1 基于有向图的深度学习构建方法和系统

本节研究了一种基于有向图的深度学习构建方法，该方法包括：① 获取初始深度学习神经网络的每个输入节点对应的输入变量之间的连接关系，得到有向图；② 确定各个输入节点与待改造隐层的隐层节点之间的匹配关系；③ 根据有向图的匹配关系确定待改造隐层的各个隐层节点之间的连接关系，得到目标深度学习神经网络。此外，本节还提供了一种深度学习构建系统。

3.1.1 研究现状

循环神经网络 (Recurrent Neural Networks, RNNs) 是深度学习家族中的一员^[22-26]，擅长解决序列化相关的问题，与传统深度学习模型不同的是，传统深度学习模型是从输入层到隐层再到输出层，层与层之间是全连接的，而每层之间的节点是无连接的，即输入节点与输入节点之间是无连接的，隐

层节点与隐层节点之间也是无连接的。而循环神经网络中一个序列当前的输出与前面的输出有关，即隐层的节点之间不再是无连接的，而是有连接的。

传统技术中，循环神经网络只能对简单的时序序列进行处理，当遇到更为复杂的时空关系及其他关系形成的序列时，就无法处理，因为循环神经网络只能处理简单的序列，限制了深度学习及深度学习在面对复杂的序列的应用。

本节针对技术现状中存在的问题，提供了一种解决复杂时序序列无法在深度学习中应用的深度学习构建方法、装置、系统和存储介质。

上述深度学习构建方法、装置、系统和存储介质，通过获取初始深度学习神经网络的所有输入节点对应的输入变量之间的连接关系，得到有向图，确定各个输入节点与待改造隐层的隐层节点之间的匹配关系，根据有向图的匹配关系确定待改造隐层的各个隐层节点之间的连接。通过对初始深度学习神经网络的隐层进行改造，将其隐层的隐层节点之间的拓扑结构采用能体现输入节点对应的输入变量的有向图来代替，得到目标深度学习神经网络。因为有向图能够体现输入变量之间的复杂序列关系，因此最终得到的目标深度学习神经网络能够处理类似有向图中的复杂序列关系。

3.1.2 基于有向图的深度学习构建方法

如图 3-1 所示，在本技术方案中，提供了一种基于有向图的深度学习构建方法，具体包括：

(1) 步骤 S1：获取初始深度学习神经网络的每个输入节点对应的输入变量之间的连接关系，得到有向图。

具体地，节点是用于创建初始深度学习神经网络的神经元，即输入层的神经元可称为输入节点。输入变量是指需要输入的变量，即初始深度学习神经网络通常要使用的变量。由于初始深度学习神经网络是通过输入变量去选

择输入节点的，因此输入层的各个输入节点都有对应的输入变量。由于初始深度学习神经网络是循环神经网络中的一种，所以输入层的输入节点之间是无连接的，但输入节点对应的输入变量之间是有连接关系的，也可称为依赖关系。这里的有向图是表示输入变量与输入变量之间的关系，其中，一个圆点表示一个变量，一条线表示一个关系。即有向图看起来是由一些小圆点(称为顶点或节点)和连接这些圆点的直线或曲线组成的，给每条线规定一个方向，得到的图称为有向图，也称为有向边。

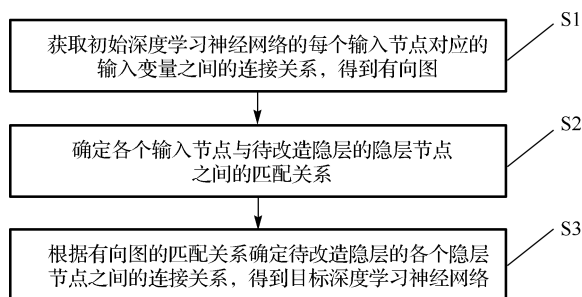


图 3-1 基于有向图的深度学习构建方法的流程图

(2) 步骤 S2：确定各个输入节点与待改造隐层的隐层节点之间的匹配关系。

具体地，待改造隐层是指对初始深度学习神经网络的其中一层的隐层进行改造。由于初始深度学习神经网络的输入节点不止一个，同样地，待改造隐层的隐层节点也不止一个，因此，需要根据输入节点的数量与待改造隐层的隐层节点的数量进行匹配。其中，包括但不限于单个输入节点可以与待改造隐层的单个隐层节点一一对应，如输入节点 A 与隐层节点 M 进行匹配，输入节点 B 与隐层节点 N 进行匹配；或多个输入节点与待改造隐层的单个隐层节点进行匹配，如输入节点 A 和输入节点 B 与隐层节点 X 进行匹配，输入节点 C 、输入节点 D 、输入节点 F 与隐层节点 Y 进行匹配；或单个输入节点与待改造隐层的多个隐层节点进行匹配，如输入节点 A 与隐层节点 X

和隐层节点 Y 进行匹配, 输入节点 B 与隐层节点 M 、隐层节点 N 及隐层节点 $M1$ 进行匹配。

(3) 步骤 S3: 根据有向图的匹配关系确定待改造隐层的各个隐层节点之间的连接关系, 得到目标深度学习神经网络。

具体地, 有向图中的匹配关系指的是有向图中输入变量之间的连接关系, 也称为依赖关系。例如, 在有向图中输入节点 A 对应的输入变量 A 指向输入节点 B 对应的输入变量 B 和输入节点 C 对应的输入变量 C , 则获取有向图中的各个输入节点对应的输入变量之间的匹配关系, 再将各个输入节点对应的待改造隐层的隐层节点按照获取到的有向图中各个输入节点对应的输入变量之间的匹配关系进行连接, 最后得到目标深度学习神经网络。又如, 隐层节点 X 与输入节点 A 连接, 输入节点 B 与隐层节点 Y 连接, 输入节点 C 与隐层节点 M 连接, 由于有向图中输入节点 A 对应的输入变量 A 指向输入节点 B 对应的输入变量 B 和输入节点 C 对应的输入变量 C , 所以隐层节点 X 与隐层节点 Y 连接, 隐层节点 X 与隐层节点 M 连接, 则成功对初始深度学习神经网络的待改造隐层进行了改造, 得到最后的目标深度学习神经网络。

1. 步骤 S1

如图 3-2 所示, 在本技术方案中, 获取初始深度学习神经网络的每个输入节点对应的输入变量之间的连接关系, 得到有向图, 步骤 S1 包括:

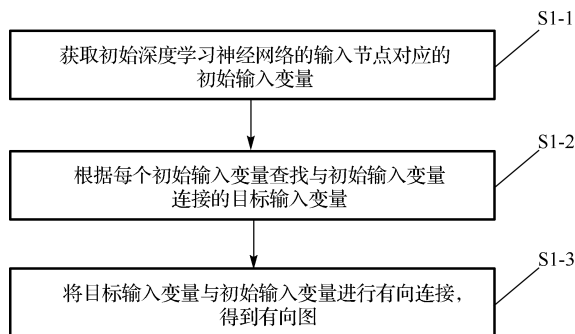


图 3-2 步骤 S1 的流程图

(1) 步骤 S1-1: 获取初始深度学习神经网络的输入节点对应的初始输入变量。

(2) 步骤 S1-2: 根据每个初始输入变量查找与初始输入变量连接的目标输入变量。

(3) 步骤 S1-3: 将目标输入变量与初始输入变量进行有向连接, 得到有向图。

其中, 输入变量是指深度学习神经网络中输入层的输入节点对应的变量, 也可以理解为深度学习神经网络中通常需要使用的变量。初始输入变量是指深度学习神经网络中输入层的输入节点一开始对应的输入变量, 目标输入变量是指与深度学习神经网络输入节点对应的初始输入变量连接的输入变量, 目标输入变量也可以理解为是指与深度学习神经网络的输入节点对应的初始输入变量相互依赖的输入变量。如果深度学习神经网络中输入层的输入节点对应的初始输入变量为 A 地前天的气象、B 地前天的气象、C 地前天的气象、A 地昨天的气象、B 地昨天的气象、C 地昨天的气象, 那么由于 A 地与 B 地相邻, B 地与 C 地相邻, 则 A 地某天气象与 B 地该天气象相互依赖, B 地某天气象与 C 地该天气象相互依赖, C 地某天气象与 A 地该天气象相互依赖。则初始输入变量为 A 地前天的气象对应的目标输入变量为 B 地前天的气象, 初始输入变量为 B 地前天的气象对应的目标输入变量为 C 地前天的气象。具体地, 由于初始深度学习神经网络输入层的输入节点之间是无连接的, 但是各个输入节点之间的输入变量之间是有连接关系的(也可称为依赖关系), 因此, 获取初始深度学习神经网络输入层的输入节点对应的初始输入变量, 再根据获取到的初始输入变量查找与初始输入变量连接的目标输入变量, 将目标输入变量与初始输入变量进行有向连接, 得到有向图。该有向图可以是一维图, 即多点在一条线上, 点与点之间通过有向线段进行连接; 也可以是二维图, 即多点在一个面上, 点与点之间通过

有向线段进行连接；也可以是三维图，即多点在一个体上，点与点之间通过有向线段进行连接；也可以是更高维图，如超图。其中，有向图中的每个节点就代表一个对应的输入节点，有向图中的有向线段就代表输入节点对应的变量之间的关系。

在本技术方案中，将目标输入变量与初始输入变量进行有向连接，得到有向图，包括：将目标输入变量作为起点，初始输入变量作为终点，初始输入变量与目标输入变量之间的关系为从起点指向终点。

由于目标输入变量与初始输入变量之间有直接依赖的连接关系用有方向的线段来体现，所以将目标输入变量作为终点，初始变量作为起点，用线连接起点与终点，箭头指向终点，即得到有向图。例如，将昨天的价格作为终点，将昨天的价格直接依赖的前天的价格作为起点，用线连接起点与终点，箭头指向终点。将今天的价格作为终点，将今天的价格直接依赖的昨天的价格作为起点，用线连接起点与终点，箭头指向终点。

2. 步骤 S2

如图 3-3 所示，在本技术方案中，确定各个输入节点与待改造隐层的隐层节点之间的匹配关系，步骤 S2 包括：

(1) 步骤 S2-1：获取待改造隐层。

(2) 步骤 S2-2：判断待改造隐层的隐层节点与输入节点是否是全连接。若是，则进入步骤 S2-3；否则，进入步骤 S2-6。

通过隐层建立与各个输入节点对应的输入变量之间的关系一致的连接，以使各个隐层节点之间的连接关系可通过隐层进行传递。具体地，获取到待改造隐层，由于初始深度神经网络的隐层不止一层，因此需对待改造隐层的层数进行判断，若待改造隐层的层数为 1，则对待改造隐层的隐层节点与输入节点之间的连接是否是全连接进行判断；但若待改造隐层的层数大于

1, 则需要根据与前一层的隐层节点之间的连接, 来判断待改造隐层的输入节点与隐层节点之间是否是全连接。其中, 当待改造隐层的层数为 1 时, 全连接是指输入节点与待改造隐层的隐层节点之间直接连接; 当待改造隐层的层数大于 1 时, 全连接是指输入节点与待改造隐层的隐层节点间虽然没有直接连接, 但是可通过多个隐层之间的连接实现连接。若这两种情况, 输入节点与待改造隐层的隐层节点之间都判断为全连接时, 则进入步骤 S2-3, 反之, 进入步骤 S2-6。

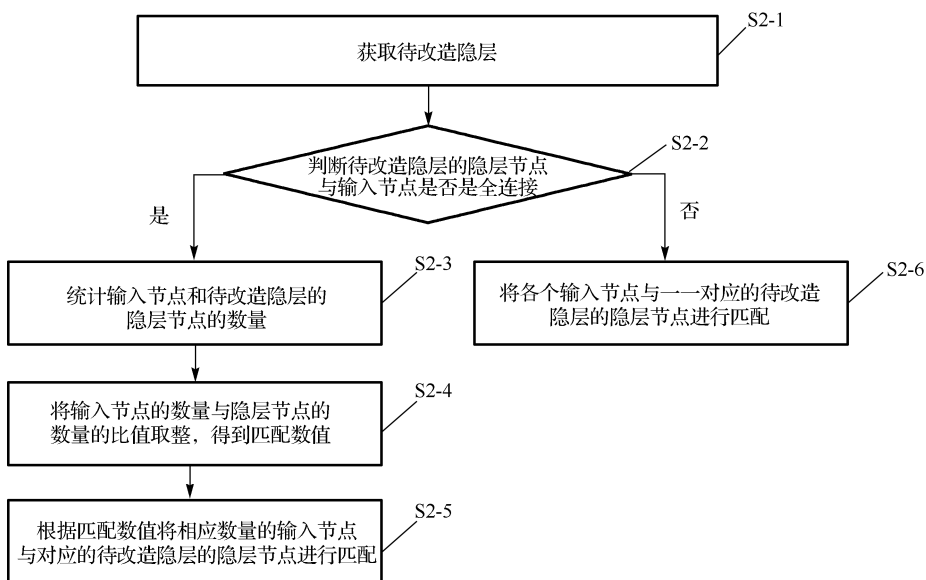


图 3-3 步骤 S2 的流程图

(3) 步骤 S2-3: 统计输入节点和待改造隐层的隐层节点的数量。

(4) 步骤 S2-4: 将输入节点的数量与隐层节点的数量比值取整, 得到匹配数值。

当待改造隐层的隐层节点与输入节点之间是全连接时, 对输入层的输入节点的数量及待改造隐层的隐层节点的数量进行统计, 将统计到的输入节点

的数量及待改造隐层的隐层节点的数量的比值取整,得到体现输入节点与待改造隐层节点之间的匹配关系的匹配数值。例如,当待改造隐层是隐层第1层时,统计输入层节点的数量为 M 、隐层第1层节点的数量为 N ,如果 M 等于 N ,那么从 $i=1$ 到 N ,输入层第 i 个输入节点对应隐层第1层第 i 个隐层节点。例如,当 $i=2$ 时,输入层的第2个输入节点对应隐层第1层的第2个隐层节点。如果 M 大于 N (如 $M=12$, $N=5$),说明输入节点的数量比待改造隐层的隐层节点的数量多,那么将 M 除以 N 并向下取整得到 $K(12/5=2.4$,向下取整为2),则 $K=2$ 为匹配数值。如果 M 小于 N (如 $N=12$, $M=5$),说明输入节点的数量比待改造隐层的隐层节点的数量少,则将 N 除以 M 并向下取整得到 $K(12/5=2.4$,向下取整为2),则 $K=2$ 为匹配数值。

(5)步骤 S2-5: 根据匹配数值将相应数量的输入节点与对应的待改造隐层的隐层节点进行匹配。

在将输入节点的数量与隐层节点的数量的比值取整,得到匹配数值后,需根据匹配数值将相应数量的输入节点与对应的待改造隐层的隐层节点进行匹配,再根据匹配数值分配好的输入节点与隐层节点数量之间的关系进行匹配。

例如,当待改造隐层是隐层第1层时,如果输入层节点的数量为 M 、隐层第1层节点的数量为 N , M 大于 N (如 $M=12$, $N=5$),则 $K=2$ 为匹配数值,那么输入层第1、2个节点对应隐层第1层第1个节点;输入层第3、4个节点对应隐层第1层第2个节点;输入层第5、6个节点对应隐层第1层第3个节点;输入层第7、8个节点对应隐层第1层第4个节点;输入层第9、10、11、12个节点对应隐层第1层第5个节点。

如果 M 小于 N (例如 $N=12$, $M=5$),得到 $K=2$,那么隐层第1层第1、2个节点对应输入层第1个节点;隐层第1层第3、4个节点对应输入层第2个节点;隐层第一层第5、6个节点对应输入层第3个节点;隐层第1层

第 7、8 个节点对应输入层第 4 个节点；隐层第 1 层第 9、10、11、12 个节点对应输入层第 5 个节点。

(6) 步骤 S2-6: 将各个输入节点与一一对应的待改造隐层的隐层节点进行匹配。

当待改造隐层的隐层节点与输入节点是非全连接时, 由于初始深度学习神经网络的隐层不止 1 层, 所以待改造隐层的隐层可能是隐层第 1 层, 也可能是隐层第 i 层 ($i > 1$)。

当待改造隐层的隐层是隐层第 1 层时, 则获取初始深度学习神经网络输入层的各个输入节点之间的连接关系, 再根据该连接关系对待改造隐层的隐层节点进行匹配。如果输入层节点 X 对应的变量直接依赖输入层节点 Y 对应的变量, 则将输入层节点 X 连接的每个隐层第 1 层节点作为终点, 将输入层节点 Y 连接的每个隐层第 1 层节点作为起点, 用线连接起点与终点, 箭头从起点指向终点。其中, X 、 Y 为输入层的 2 个不同节点。又如, 输入层节点 X 连接隐层第 1 层 A 、 B 、 C 节点, 输入层节点 Y 连接隐层第 1 层 D 、 E 节点, 则用线连接 D 与 A , 箭头从 D 指向 A ; 用线连接 E 与 A , 箭头从 E 指向 A ; 用线连接 D 与 B , 箭头从 D 指向 B ; 用线连接 E 与 B , 箭头从 E 指向 B ; 用线连接 D 与 C , 箭头从 D 指向 C ; 用线连接 E 与 C , 箭头从 E 指向 C 。

当待改造隐层的隐层不是隐层第 1 层时, 则获取初始深度学习神经网络的输入层的各个输入节点之间的连接关系, 再根据该连接关系对待改造隐层的隐层节点进行匹配。例如, 如果输入层节点 X 对应的变量直接依赖于输入层节点 Y 对应的变量, 则将输入层节点 X 连通的每个隐层的第 i 层节点作为终点, 将输入层节点 Y 连通的每个隐层的第 i 层节点作为起点, 用线连接起点与终点, 箭头从起点指向终点。其中, X 、 Y 为输入层的 2 个不同节点。其中, 连通指的是虽然从输入层节点到隐层第 i 层节点没有直接连接, 但可通过多个层次之间的连接实现连通。例如 $i=2$ 时, 输入层节点 X 连接隐

层第1层节点 S ，隐层第1层节点 S 连接隐层第2层节点 A ，则输入层节点 X 连通隐层第2层节点 A 。

若待改造隐层的隐层是多个，则对其中每个层根据其层数执行上述步骤，其层数为隐层第1层时，执行当待改造隐层的隐层是隐层第1层时的步骤，其层数为隐层第 i 层时，执行当待改造隐层的隐层是隐层第 i 层时的步骤。

3. 步骤 S3

如图3-4所示，在本技术方案中，根据有向图的匹配关系确定待改造隐层的各个隐层节点之间的连接关系，得到目标深度学习神经网络，步骤S3包括：




图3-4 步骤S3的流程图

(1) 步骤S3-1：获取有向图中各个输入变量之间的匹配关系。

(2) 步骤S3-2：根据各个输入变量对应的输入节点与相应的隐层节点之间的匹配关系，将各个隐层节点根据有向图中的匹配关系进行有向连接，得到目标深度学习神经网络。

有向图是表示输入变量与输入变量之间关系的方法，用一个圆点来表示一个输入变量，用一条线来表示一个关系。有向图看起来是由一些小圆点(称为顶点或者节点)和连接这些圆点的直线或曲线组成的。获取有向图中各个输入节点对应的输入变量之间的匹配关系，由于各个输入变量有对

应的输入节点，则可根据输入节点与相应的隐层节点之间的匹配关系，对待改造隐层的隐层节点根据匹配关系进行有向连接，最终得到目标深度学习神经网络。其中，可将输入节点的数量与隐层节点的数量比值取整，得到匹配数值，再根据匹配数值，分配相应数量的输入节点对应隐层节点，将有向连接中以标记为终点的输入变量对应的输入节点连接的隐层节点作为终点，以标记为起点的输入变量对应的输入节点连接的隐层节点作为终点，用线将起点指向终点，建立连接。

3.1.3 基于有向图的深度学习构建系统

如图 3-5 所示，在本技术方案中，提供了一种基于有向图的深度学习构建系统，该系统包括：

(1) 有向图生成模块 1，用于获取初始深度学习神经网络中的每个输入节点对应的输入变量之间的连接关系，得到有向图。

(2) 匹配模块 2，用于确定各个输入节点与待改造隐层的隐层节点之间的匹配关系。

(3) 目标深度学习神经网络确定模块 3，用于根据有向图所述的匹配关系确定待改造隐层的各个隐层节点之间的连接关系，得到目标深度学习神经网络。




图 3-5 基于有向图的深度学习构建系统的结构图

1. 有向图生成模块 1

在本技术方案中，如图 3-6 所示，有向图生成模块 1 包括：获取单元 1-1、查找单元 1-2 及连接单元 1-3。




图 3-6 有向图生成模块的结构图

- (1) 获取单元 1-1，用于获取初始深度学习神经网络的输入节点对应的初始输入变量。
- (2) 查找单元 1-2，用于根据每个初始输入变量查找与初始输入变量连接的目标输入变量。
- (3) 连接单元 1-3，用于将目标输入变量与初始输入变量进行有向连接，得到有向图。将目标输入变量作为起点，初始输入变量作为终点，初始输入变量与目标输入变量之间的有向连接为从起点指向终点。

2. 匹配模块 2

- 在本技术方案中，匹配模块 2 包括隐层获取单元和第一检测单元。
- (1) 隐层获取单元，用于获取待改造隐层。
 - (2) 第一检测单元，用于当待改造隐层的隐层节点与输入节点不是全连接时，将各个输入节点一一对应地与待改造隐层的隐层节点进行匹配。
- 匹配模块 2 还可包括第二检测单元、计算单元及分配单元，其中：
- (1) 第二检测单元，当待改造隐层的隐层节点与输入节点是全连接时，统计输入节点和待改造隐层的隐层节点的数量。

(2) 计算单元，将输入节点的数量与隐层节点的数量比值取整，得到匹配数值。

(3) 分配单元，根据匹配数值将相应数量的输入节点与对应的待改造隐层的隐层节点进行匹配。

3. 目标深度学习神经网络确定模块 3

在本技术方案中，目标深度学习神经网络确定模块 3 还用于获取有向图中各个输入变量之间的匹配关系；根据各个输入变量对应的输入节点与相应的隐层节点之间的匹配关系，将各个隐层节点根据有向图中的匹配关系进行有向连接，得到目标深度学习神经网络。

3.2 深度学习神经网络训练及层数调整方法和系统

本节研究了一种深度学习神经网络训练及层数调整方法和系统。该方法包括：获取训练输入数据；将训练输入数据输入当前深度学习神经网络进行训练，得到训练结果信息，当前深度学习神经网络包括输入层、隐层、分类器和输出层；若训练结果信息不符合预设条件，则调整当前深度学习中隐层的层数以更新当前深度学习神经网络，并返回将训练输入数据输入当前深度学习神经网络进行训练，得到训练结果信息的步骤；否则将当前深度学习神经网络作为训练后的深度学习神经网络。如此，通过在训练过程中根据训练结果信息进行隐层层数的调整，直至训练结果信息符合预设条件，可确保深度学习神经网络训练成功。

3.2.1 研究现状

深度学习是一种进行分布式并行信息处理的算法数学模型，常用于智能

机器识别,深度学习可采用样本数据进行学习,包括有监督学习和无监督学习^[27-29]。

传统技术中,通常将不带标签的样本数据输入固定层数的深度学习神经网络进行无监督学习,将带有标签的样本数据输入固定层数的深度学习神经网络进行有监督学习,并得到输出标签,以完成对深度学习神经网络的训练,并在训练后用测试数据进行测试。例如,输出标签为身份证号码,可以采用头像作为样本数据,输入头像得到该人的身份证号码,或者采用语音作为样本数据,输入语音得到该人的身份证号码。

然而,在有监督学习的过程中,如果深度学习神经网络的层数过少,使顶层概念过于具体,与输出标签判别无关甚至矛盾,从而使顶层概念与输出标签不能充分拟合,会导致输入样本数据后,得不到正确的输出标签,深度学习神经网络训练失败;而如果深度学习神经网络的层数过多,会使顶层概念过于抽象,缺少判别的细节,而在有监督学习过程中加入刚好能区分输出标签的“噪声”细节,从而使顶层概念与输出标签过拟合,会导致输入样本数据后,都得到正确的输出标签,但输入测试数据后,很多得不到正确的输出标签,从而导致深度学习神经网络训练失败。

基于此,有必要针对传统的深度学习神经网络训练成功率低的问题,提供一种可提高训练成功率的深度学习神经网络训练方法和系统。将训练输入数据输入当前深度学习神经网络进行训练,得到训练结果信息,若训练结果信息不符合训练成功的预设条件,则调整当前深度学习神经网络中隐层的层数,以更新当前深度学习神经网络,并重新将训练数据输入更新后的当前深度学习神经网络进行训练,重复分析是否符合预设条件;若训练结果信息符合预设条件,表示训练成功,则将当前深度学习神经网络作为训练后的深度学习神经网络。如此,在训练过程中,根据训练结果信息调整隐层层数,直至训练结果信息符合预设条件,可确保深度学习神经网络

络训练成功。相比于传统的训练方法，本训练方法和层数调整装置的训练成功率更高。

3.2.2 深度学习神经网络训练及层数调整方法

在有监督学习的过程中，如果层数过多，会使顶层概念过于抽象，缺少判别的细节，而加入刚好能区分输出标签的“噪声”细节，会使顶层概念与输出标签过拟合。在训练中为了拟合而在顶层概念中加入了非区别性特征的噪声，必然导致后面测试中的错误率增大。例如，输出标签包括“白色男人”“白色女人”“黑色男人”“黑色女人”，而顶层概念抽象成了“男人”“女人”特征，忽略了“黑色”“白色”特征，此时所有的样本数据都能拟合成“男人”“女人”这两个标签上，深度学习神经网络采用的是自下而上的无监督学习和自顶向下的有监督学习，“白色男人”“黑色男人”这两类样本数据显然都能与“男人”顶层概念对应，“白色女人”“黑色女人”这两类样本数据显然都能与“女人”顶层概念对应。通过有监督学习，深度学习神经网络会自动调整网络权值，最终使“男人+噪声 1”顶层概念对应“黑色男人”，“男人+噪声 2”顶层概念对应“白色男人”，“女人+噪声 3”顶层概念对应“黑色女人”，“女人+噪声 4”顶层概念对应“白色女人”。由于在有监督学习过程中进行了反复拟合，因此对训练数据而言达到了充分拟合的效果。在应用时，输入“白色男人”测试数据，得到的顶层概念为“男人+噪声 2”，因为噪声 2 并不是区分白色男人与黑色男人的区别性特征，此时通过分类器对应的输出标签可能是“白色男人”，也可能是“黑色男人”，甚至会由于噪声 2 的干扰，得到的输出标签是“白色女人”或“黑色女人”，从而使测试时错误率加大，训练失败。

如果层数过少，会使顶层概念过于具体，与输出标签判别无关甚至矛盾，从而使顶层概念与输出标签不能拟合。也就是说，无法使顶层概念与输出标

签一一对应。例如，输出标签包括“男人”“女人”，而顶层概念的特征除包括区别男、女的必要特征外，还包括头发特征、肤色特征。在自顶向下的有监督学习中，如果刚开始有很多“短发男人”“黑色男人”“白色女人”“长发女人”的训练样本，那么就会使顶层概念中形成“短发男人”“黑色男人”“白色女人”“长发女人”的概念，其中“短发男人”“黑色男人”通过分类器对应“男人”输出标签，“白色女人”“长发女人”通过分类器对应“女人”输出标签，但如果后来又有大量“长发男人”“黑色女人”的训练样本，就会使顶层概念调整为“长发男人”“黑色男人”“黑色女人”“长发女人”，调整之后显然又无法拟合“短发男人”“白色女人”那些样本数据，从而导致深度学习神经网络随着样本数据的变化不断地调整网络权值，却始终无法充分拟合，训练失败。

本节研究一种深度学习神经网络训练及层数调整方法。如图 3-7 所示，在本技术方案中，深度学习神经网络训练方法包括如下步骤。

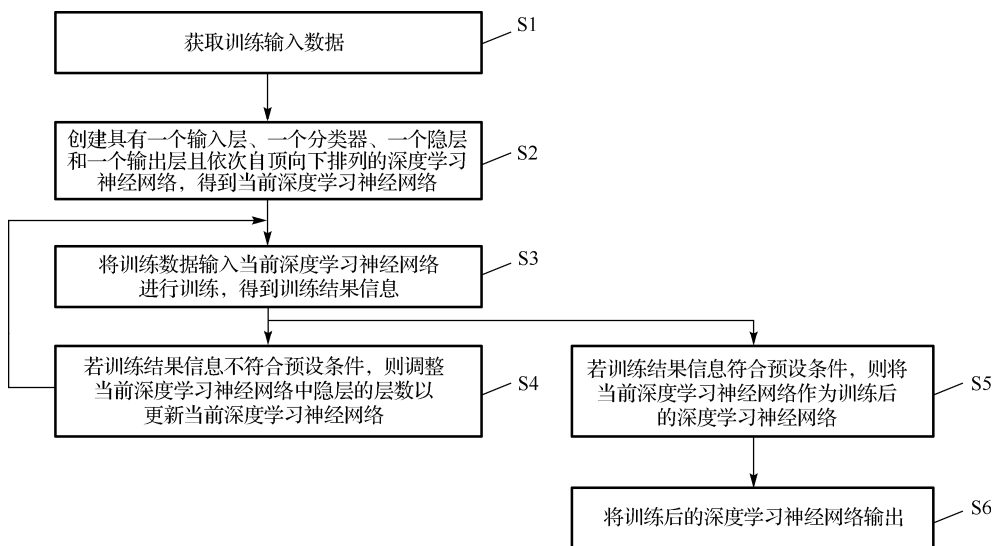


图 3-7 深度学习神经网络训练及层数调整方法的流程图

(1) 步骤 S1：获取训练输入数据。

训练输入数据是用于深度学习神经网络训练的样本数据。例如，训练输入数据可以是人脸图像，也可以是语音。具体地，训练输入数据可以通过采集获取，例如，通过摄像头采集，获取人脸图像，或通过语音接收器采集，获取语音；训练输入数据也可以从数据库中查找获取，例如，预先在数据库中存储人脸图像或语音，从数据库中搜索人脸图像或语音即可得到训练输入数据。

(2) 步骤 S2：创建具有一个输入层、一个分类器、一个隐层和一个输出层且依次自顶向下排列的深度学习神经网络，得到当前深度学习神经网络。

创建具有一个隐层的深度学习神经网络作为初始的深度学习神经网络，如图 3-8 所示，以最少层数的隐层为基础，以便后续增加隐层。例如，本技术方案为在步骤 S3 之后创建深度学习神经网络。步骤 S2 可以在步骤 S3 之前，也可以在步骤 S3 之后。




图 3-8 具有一个输入层、一个分类器、一个隐层和一个输出层的深度学习神经网络模型图

(3) 步骤 S3：将训练数据输入当前深度学习神经网络进行训练，得到训练结果信息。

当前深度学习神经网络是已经创建好的深度学习神经网络，包括输入层、隐层、分类器和输出层。其中，分类器是罗杰斯特回归分类器、SVM(Support Vector Machine，支持向量机)分类器中的任意一种。具体地，

第一次执行步骤 S3 时，对应的当前深度学习神经网络为预先创建存储的深度学习神经网络。

步骤 S3 包括步骤 S3-1 至步骤 S3-3，如图 3-9 所示。

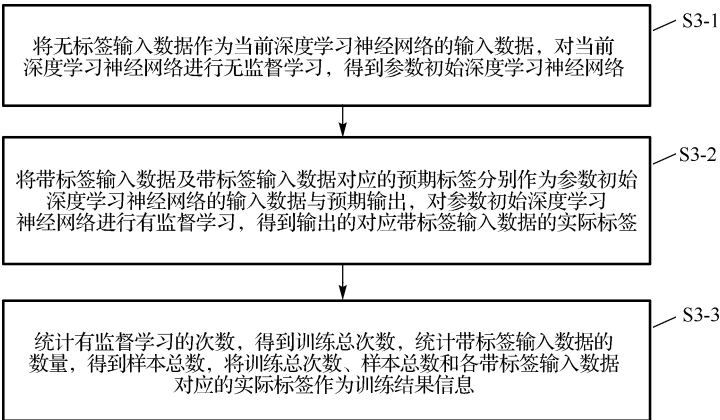


图 3-9 深度学习神经网络训练方法的流程图

① 步骤 S3-1：将无标签输入数据作为当前深度学习神经网络的输入数据，对当前深度学习神经网络进行无监督学习，得到参数初始深度学习神经网络。

其中，无标签输入数据可以有多个。依次将各无标签输入数据输入当前深度学习，对应完成一轮无监督学习，则一轮无监督学习对应的无监督学习的次数等于无标签输入数据的数量。也可以从所有的无标签输入数据中选取预设数量的无标签输入数据，输入当前深度学习神经网络以完成一轮无监督学习，其他未被选取的不使用。此时，一轮无监督学习对应的无监督学习的次数小于无标签输入数据的数量，等于预设数量。

② 步骤 S3-2：将带标签输入数据及带标签输入数据对应的预期标签分别作为参数初始深度学习神经网络的输入数据与预期输出，对参数初始深度学习神经网络进行有监督学习，得到输出的对应带标签输入数据的实际标签。

其中，带标签输入数据可以有多个。依次将各带标签输入数据及带标签输入数据对应的预期标签作为参数初始深度学习神经网络的输入数据和预期输出，对应完成一轮有监督学习，则一轮有监督学习对应的有监督学习的次数等于带标签输入数据的数量。也可以从所有的带标签输入数据中选取预设数量的带标签输入数据输入参数初始深度学习神经网络以完成一轮有监督学习，其他未被选取的不使用。此时，一轮有监督学习对应的有监督学习的次数小于带标签输入数据的数量，等于预设数量。

③ 步骤 S3-3：统计有监督学习的次数，得到训练总次数，统计带标签输入数据的数量，得到样本总数，将训练总次数、样本总数和各带标签输入数据对应的实际标签作为训练结果信息。

样本总数是获取的带标签输入数据的总数量；训练总次数是通过统计有监督学习的次数得到的，其中，每采用一个带标签输入数据和对应的预期标签，就对应进行一次有监督学习。若进行一轮有监督学习需要使用所有的带标签输入数据，则完成一轮有监督学习，对应有监督学习的次数等于样本总数，即训练总次数等于样本总数；若完成两轮有监督学习，则对应有监督学习的次数等于样本总数的两倍，即训练总次数等于样本总数的两倍，以此类推。可以理解，若进行一轮有监督学习，使用所有带标签输入数据的部分带标签输入数据，则完成一轮有监督学习，对应有监督学习的次数小于样本总数，即训练总次数小于样本总数，以此类推。

(4) 步骤 S4：若训练结果信息不符合预设条件，则调整当前深度学习神经网络中隐层的层数以更新当前深度学习神经网络，并返回步骤 S3。

预设条件表示训练成功的条件，可以根据实际需求设置。可以通过对训练结果信息进行分析，判断训练结果信息是否符合预设条件。若训练结果信息不符合预设条件，表示还未训练成功，当前深度学习神经网络的顶层概念与输出标签不能拟合，此时，可通过调整隐层的层数以更新当前深度学习神

神经网络，来增加顶层概念与输出标签拟合的程度。调整隐层的层数可以是增加新的隐层，也可以是减少隐层。

(5) 步骤 S5：若训练结果信息符合预设条件，则将当前深度学习神经网络作为训练后的深度学习神经网络。

若训练结果信息符合预设条件，表示训练成功，当前深度学习神经网络能达到顶层概念与标签拟合；此时，结束训练，将当前深度学习神经网络作为训练后的神经网络。具体地，若符合预设条件的训练结果信息为更新后的当前深度学习神经网络对应的训练结果信息，则将对更新后的当前深度学习神经网络作为训练后的深度学习神经网络。

(6) 步骤 S6：将训练后的深度学习神经网络输出。

训练后的深度学习神经网络为成功拟合的神经网络，可用于机器学习。

在本技术方案中，训练输入数据包括无标签输入数据、带标签输入数据和各带标签输入数据对应的预期输出标签。

无标签输入数据是没有携带标签的数据，带标签输入数据是携带标签的数据。每个带标签输入数据对应一个预期输出标签，带标签输入数据和预期输出标签可预先对应存储。其中，预期输出标签是一种标识信息。例如，无标签输入数据为单一的人脸图像，带标签输入数据为携带有身份证号码的人脸图像，预期输出标签为携带有身份证号码的人脸图像所对应的用户的真实身份证号码。

具体地，在本技术方案中，步骤 S4 调整当前深度学习神经网络中隐层的层数以更新当前深度学习神经网络，是在当前深度学习神经网络中插入一个隐层，得到新的当前深度学习神经网络。如此，步骤 S4 每执行一次，当前深度学习神经网络中隐层的层数就会增加一层。例如，最初隐层只有一层；步骤 S4 执行一次后，隐层变成 2 层；步骤 S4 执行 2 次后，隐层变成 3 层，以此类推。通过逐步增加隐层的层数，并通过预设条件分析判断，检查拟合

的情况，使神经网络能够逐渐达到刚好充分拟合的状态，而不会因为盲目地增加层数导致过拟合。

调整当前深度学习神经网络中隐层的层数以更新当前深度学习，具体包括：创建新插入的隐层，将深度学习神经网络中最后一个隐层的输出与新插入的隐层的输入通过编解码网络相连，将新插入的隐层的输出作为分类器的输入，以更新当前深度学习神经网络。

本技术方案通过最初只设定一层隐层，对隐层进行无监督学习，然后加上分类器自顶向下进行有监督学习。如果训练结果信息符合预设条件，则拟合成功，完成有监督训练；若不符合预设条件，则拟合失败，切断分类器前一隐层与分类器之间的连接，并在分类器前一隐层与分类器之间插入一个新的隐层，将分类器前一隐层连接到新的隐层，将新的隐层连接到分类器，然后重复无监督学习和有监督学习，直至拟合成功。如此，达到充分拟合时，分类器的前一隐层概念就是足以与输出标签进行充分拟合的概念，能刚好达到充分拟合而不过分拟合。

具体地，本技术方案中，新插入的隐层的节点数小于或等于新插入的隐层所连接的隐层的节点数。新插入的隐层所连接的隐层即为更新之前连接分类器的最后一个隐层。通过让新插入的隐层的节点数小于或等于最后一个隐层的节点数，可以使输入分类器的顶层概念更为抽象，忽略无法与输出标签进行映射的特征，抽象出能与输出标签充分对应的特征。

可以理解，在其他技术方案中，步骤 S2 也可以是先建立一个具有多个隐层的当前深度学习神经网络。若训练结果信息不符合预设条件，则在步骤 S4 中减少一个隐层后返回步骤 S3。

3.2.3 深度学习神经网络训练及层数调整系统

如图 3-10 所示，在本技术方案中，提供了一种层数调整系统，包括数

据获取模块 1、网络创建模块 2、网络训练模块 3、层数调整模块 4、训练结束模块 5、网络输出模块 6。

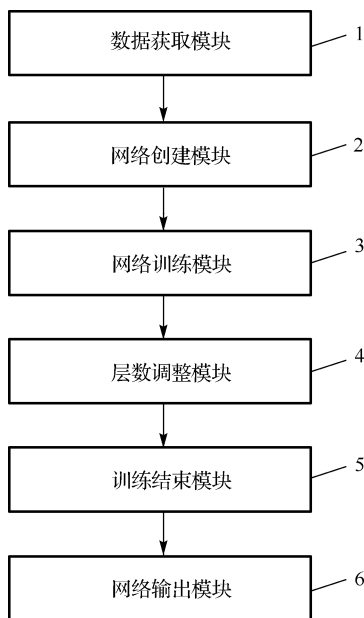


图 3-10 层数调整系统的结构图

(1) 数据获取模块 1，用于获取训练输入数据。

(2) 网络创建模块 2，用于创建一个输出层、一个分类器、一个隐层、一个输入层且依次自顶向下排列的深度学习神经网络，得到当前深度学习神经网络。

创建一个隐层的深度学习神经网络作为初始的深度学习神经网络，以最少层数的隐层为基础，以便后续增加隐层。具体地，网络创建模块在网络训练模块 3 执行相应功能之前创建得到当前的深度学习神经网络。

(3) 网络训练模块 3，用于将训练数据输入当前深度学习神经网络进行训练，得到训练结果信息。当前深度学习神经网络包括输入层、隐层、分类器和输出层。

(4) 层数调整模块 4，用于当训练结果信息不符合预设条件时，调整当前深度学习神经网络中隐层的层数，以更新当前深度学习神经网络，并返回网络训练模块 3 重新将训练数据输入当前深度学习神经网络进行训练，得到训练结果信息。

(5) 训练结束模块 5，用于当训练结果信息符合预设条件时，将当前深度学习神经网络作为训练后的深度学习神经网络。

(6) 网络输出模块 6，用于将训练后的深度学习神经网络输出。

训练后的深度学习神经网络为成功拟合的神经网络，用于机器自学习。

在本技术方案中，训练输入数据包括无标签输入数据、带标签输入数据和各带标签输入数据对应的预期输出标签。网络训练模块 3 包括无监督学习单元、有监督学习单元和信息统计单元。无监督学习单元将无标签输入数据作为当前深度学习神经网络的输入数据，对当前深度学习神经网络进行无监督学习，得到参数初始深度学习神经网络。有监督学习单元将带标签输入数据及带标签输入数据对应的预期输出标签分别作为参数初始深度学习神经网络的输入数据与预期输出，对参数初始深度学习神经网络进行有监督学习，得到带标签输入数据的实际输出标签。信息统计单元统计有监督学习的次数，得到训练总次数，统计带标签输入数据的数量，得到样本总数，将训练总次数、样本总数和各带标签输入数据对应的实际输出标签作为训练结果信息。

具体地，在本技术方案中，层数调整模块 4 调整当前深度学习神经网络中隐层的层数，以更新当前深度学习神经网络，是在当前深度学习神经网络中插入一个隐层，得到新的当前深度学习神经网络。通过逐步增加隐层的层数，并通过预设条件的分析判断检查拟合的情况，使能够逐渐达到刚好充分拟合的状态，而不会因为盲目地增加层数导致过拟合。

具体地，层数调整模块 4 创建新插入的隐层，将深度学习神经网络中最后一个隐层的输出与新插入的隐层的输入通过编解码网络相连，将新插入的隐层的输出作为分类器的输入，以更新当前深度学习神经网络。

可以理解，在其他技术方案中，网络创建模块 2 也可以是先建立一个具有多个隐层的当前深度学习神经网络。层数调整模块 4 在训练结果信息不符合预设条件时，减少一个隐层。

The background features a large, curved, metallic-looking surface with a grid of small circular perforations. A sphere with a similar perforated pattern is positioned in the lower right foreground, casting a soft shadow. The overall aesthetic is modern and technical.

第二部分 应用实践

第 4 章 深度学习的大数据智能计算应用

本章给出了两种深度学习的大数据智能计算应用：基于大数据与深度学习的信息隐藏、提取方法和系统，基于大数据与深度学习的婚恋对象匹配数据处理方法和系统。

4.1 基于大数据与深度学习的信息隐藏、提取方法和系统

本节研究了一种基于大数据与深度学习的信息隐藏、提取方法和系统，所述方法可以将信息隐藏在大数据中，并且通过深度学习神经网络训练，确保秘密信息的安全性。拥有秘密信息访问权限的用户能够从大数据中通过合成提取秘密信息，网络开销、存储开销、计算开销都极低。

4.1.1 研究现状

信息隐藏^[30-35]的基本原理是：假设 A 打算秘密传递一些信息给 B，A 需要从一个随机消息源中随机选取一个无关紧要的消息 C，这个消息传递时，不会引起人们的怀疑，这个消息 C 称为载体对象 (Cover Message)；把秘密信息 (Secret Message) M 隐藏到载体对象 C 中，此时，载体对象就变成了伪装对象 C1。载体对象 C 是正常的，不会引起人们的怀疑，伪装对象 C1 与载体对象 C 无论从感官 (如感受图像、视频的视觉和感受声音、

音频的听觉)上,还是从计算机的分析上都不能被区分开来,而且对伪装对象 C1 的正常处理,不破坏隐藏的秘密信息。这样就实现了信息的隐藏传输。

由于载体对象和伪装对象的数据量有限,目前的信息隐藏技术无法隐藏大批量的秘密信息,从载体对象和伪装对象中分析挖掘出秘密信息的复杂度和难度也有限,从而使秘密信息有可能被破解,导致信息隐藏的安全性不高。

本节的第一个研究目的是解决上述现有的技术缺陷,提供一种信息隐藏方法,该方法可以将信息隐藏在大数据中,并且通过深度学习神经网络训练,确保秘密信息的安全性。

本节的第二个研究目的是提供一种信息提取方法,该方法可以使拥有秘密信息访问权限的用户能够从大数据中通过合成提取秘密信息,其网络开销、存储开销、计算开销都极低。

相对于现有技术,本节提出的方法具有如下优势:

(1)在信息隐藏阶段时,可以将包含需要隐藏的秘密信息的某个数据插入大数据中,基于大数据的隐藏技术,使秘密信息被破解的可能性降低,导致信息隐藏的安全性极高。同时由于载体对象和伪装对象的数据量大,可以隐藏大批量的秘密信息,获取大数据中该数据的所在位置,从该数据中获取需要隐藏的秘密信息,将该数据及需要隐藏的秘密信息分别作为预设深度学习神经网络的输入和输出进行训练,再将该数据输入训练后的深度学习神经网络,得到该网络输出的第一信息,将秘密信息与第一信息之间的差异作为第二信息,经过这样处理后,需要获得大数据中该数据的位置、第二信息和训练后的深度学习神经网络才可以提取秘密信息。而对大数据拥有访问权限,但对秘密信息不拥有访问权限的用户是不知道这些信息的,因此无法通过大数据提取秘密信息,确保了秘密信息的安全性。

(2)在信息隐藏阶段时,可以将需要隐藏的秘密信息进行切分,切分成多个秘密子信息,并进行编号,从大数据中选取多个数据,并将多个数据与多个秘密子信息进行一一对应,使多个秘密子信息分散到大数据的对应数据中。在实现大容量隐藏的同时,充分保证了秘密信息的高隐蔽性。同样地,将每个数据对应的秘密子信息作为预设深度学习神经网络的输入和输出进行训练,再将每个数据输入训练后的深度学习神经网络,得到该网络输出的对应第一信息,将每个秘密子信息与对应第一信息之间的差异作为对应的第二信息。经过这样处理后,需要获得大数据中多个数据的位置、多个秘密子信息的编号、多个第二信息和训练后的深度学习神经网络,才可以提取秘密信息。而对大数据拥有访问权限,但对秘密信息不拥有访问权限的用户是不知道这些信息的,因此无法通过大数据提取秘密信息,确保了秘密信息的安全性。

(3)在信息提取阶段时,由于第一信息是以秘密信息为预期输出的深度学习神经网络的实际输出,因此第一信息与秘密信息的差异很小,即第二信息的数据量很小;而深度学习神经网络是以网络权值的形式表示,其数据量也很小;所以只要将数据量很小的大数据中包含需要隐藏的秘密信息的某个数据所在位置、第二信息及训练后的深度学习发送给拥有秘密信息访问权限的用户,就可以使该用户能够从大数据中通过合成提取秘密信息,其网络开销、存储开销、计算开销都极低。

(4)在信息提取阶段时,或只要将数据量很小的大数据中包含对应秘密子信息的多个数据所在位置、多个第一编号、多个第二信息、训练后的深度学习神经网络发送给拥有秘密信息访问权限的用户,就可以使该用户从大数据中通过合成提取秘密信息,其网络开销、存储开销、计算开销都极低。

4.1.2 基于大数据与深度学习的信息隐藏、提取方法

1. 技术方案 1

如图 4-1 所示，本技术方案提供了一种信息隐藏方法，包括以下步骤：

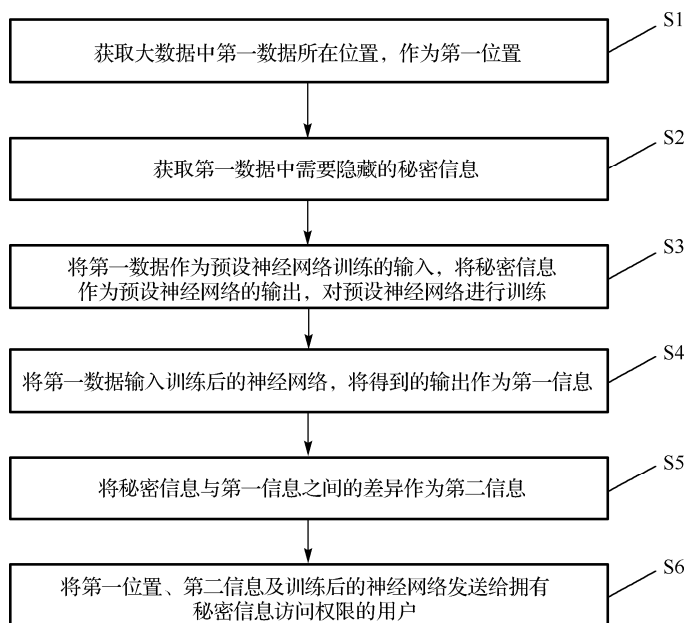


图 4-1 信息隐藏方法流程图

(1) 步骤 S1：获取大数据中第一数据所在位置，作为第一位置。

本技术方案是基于大数据搜索的信息隐藏技术，由于载体对象和伪装对象的数据量极大，可以隐藏大批量的秘密信息，因此从数据量极大的载体对象和伪装对象中分析挖掘出秘密信息的复杂度和难度非常高，如同“大海捞针”，从而使秘密信息极不可能被破解，导致信息隐藏的安全性极高。

例如，大数据中的第一数据为图像文件 P，P 所在位置为“P1 数据中心-P2 机房-P3 机柜-P4 节点-P5 磁盘-P6 文件路径-P7 文件”，则将该位置作为第一位置。

(2) 步骤 S2：获取第一数据中需要隐藏的秘密信息。

本技术方案需要隐藏的是第一数据中的部分信息，例如，以第一数据为图像文件 P 进行说明，P 中需要隐藏的秘密信息是一个人脸图像 F，将人脸图像 F 从图像文件 P 中提取出来。

(3) 步骤 S3：将第一数据作为预设神经网络训练的输入，将秘密信息作为预设神经网络的输出，对预设神经网络进行训练。

继续以图像文件 P 为第一数据，需要隐藏的秘密信息为人脸图像 F，将 P 作为预设神经网络训练的输入，将人脸图像 F 作为预设神经网络的输出，对预设神经网络进行训练。

(4) 步骤 S4：将第一数据输入训练后的神经网络，将得到的输出作为第一信息。

将图像文件 P 输入训练后的神经网络，由该神经网络进行计算，将得到的输出作为第一信息。

(5) 步骤 S5：将秘密信息与第一信息之间的差异作为第二信息。

将人脸图像 F 与第一信息之间的差异作为第二信息，其中，第二信息=人脸图像 F-第一信息。

(6) 步骤 S6：将第一位置、第二信息及训练后的神经网络发送给拥有秘密信息访问权限的用户。

2. 技术方案 2

如图 4-2 所示，本技术方案提供了一种信息提取方法，该方法与技术方案 1 中的信息隐藏方法相对应，包括以下步骤：

(1) 步骤 S7: 获取第一位置、第二信息及训练后的神经网络。

由于对大数据拥有访问权限,但对秘密信息不拥有访问权限的用户不知道第一位置、第二信息、训练后的神经网络,因此无法通过大数据提取秘密信息,确保了秘密信息的安全性。

由于第一信息是以秘密信息为预期输出的神经网络的实际输出,因此第一信息与秘密信息的差异很小,即第二信息的数据量很小;而神经网络是以网络权值的形式表示,其数据量也很小;所以只要将数据量很小的第一位置、第二信息及训练后的神经网络发送给对拥有秘密信息访问权限的用户,就可以使用该用户从大数据中通过合成提取秘密信息,其网络开销、存储开销、计算开销都极低。

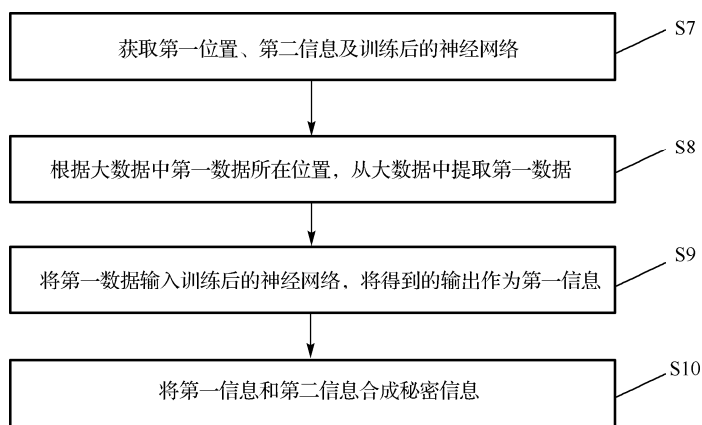


图 4-2 信息提取方法流程图

(2) 步骤 S8: 根据大数据中第一数据所在位置,从大数据中提取第一数据。

本技术方案根据第一位置“P1 数据中心-P2 机房-P3 机柜-P4 节点-P5 磁盘-P6 文件路径-P7 文件”,从大数据中提取图像文件 P。

(3) 步骤 S9: 将第一数据输入训练后的神经网络,将得到的输出作为第一信息。

由于在技术方案 1 的信息隐藏中,将图像文件 P 输入训练后的神经网络,将得到的输出作为第一信息,因此在本技术方案中,也将图像文件 P 输入训练后的神经网络,将得到的输出作为第一信息。

(4) 步骤 S10: 将第一信息和第二信息合成秘密信息。

由于在技术方案 1 的信息隐藏中,将人脸图像 F 与第一信息之间的差异作为第二信息,可知第二信息=人脸图像 F-第一信息。也就是说,人脸图像 F=第一信息+第二信息,所以,将第一信息和第二信息合成,即可恢复出秘密信息人脸图像 F。

3. 技术方案 3

如图 4-3 所示,本技术方案提供了一种信息隐藏方法,该方法包括以下步骤:

(1) 步骤 S1: 获取需要隐藏的秘密信息。

本技术方案将一些秘密信息进行隐藏,因此首先获取需要隐藏的秘密信息,记为 S。例如,需要隐藏的秘密信息是 100 段话。

(2) 步骤 S2: 将秘密信息切分成多个秘密子信息,并将多个秘密子信息在秘密信息中的相对位置作为多个第一编号。

本技术方案中,将秘密信息 S 切分成 p 个信息 S1、S2、...、Sp,并将 p 个秘密子信息在秘密信息 S 中的相对位置作为该 p 个秘密子信息的编号 W1、W2、...、Wp,作为 p 个第一编号,其中 $p \geq 2$ 。

以需要隐藏的秘密信息是 100 段话为例,将每段话有序切分为 100 个字符串(如果一段话不足 100 个字符,则 100 个字符串中可以包括空串),从而得到 10 000 个字符串,某字符串的位置编号的前 3 位表示是第几段话,后 3 位表示是该段话的第几个字符串,例如,位置编号 004006 表示该字符串是第 4 段话中的第 6 个字符串;位置编号 014026 表示该字符串是第 14 段话

中的第 26 个字符串；位置编号 042051 表示该字符串是第 42 段话中的第 51 个字符串。

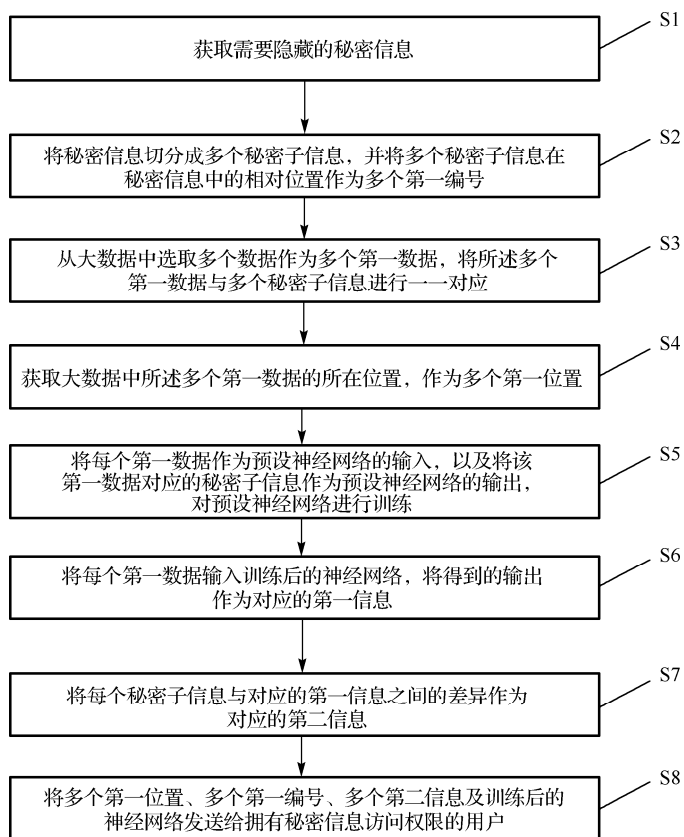


图 4-3 信息隐藏方法流程图

(3) 步骤 S3：从大数据中选取多个数据作为多个第一数据，将所述多个第一数据与多个秘密子信息进行一一对应。

本技术方案中，从大数据中选取 p 个数据 $D1$ 、 $D2$ 、 \dots 、 Dp ，作为 p 个第一数据，将 p 个第一数据与 p 个秘密子信息进行一一对应。

以 p 个第一数据为 p 个图像文件为例，将 p 个图像文件与 p 个秘密子信息进行一一对应，即 $D1$ 与 $S1$ 对应， $D2$ 与 $S2$ 对应， \dots ， Dp 与 Sp 对应。

(4) 步骤 S4: 获取大数据中所述多个第一数据的所在位置, 作为多个第一位置。

本技术方案中, 获取大数据中所述的 p 个第一数据的所在位置, 作为与 p 个第一数据对应的 p 个第一位置, 其中, 位置包括存储位置、路径、索引号或编号, 通过 p 个第一位置可以从大数据中定位到 p 个第一数据。

具体地, 大数据中所述的 p 个第一数据 $D1$ 、 $D2$ 、 \cdots 、 Dp 所在位置为 p 个对应的第一位置 $L1$ 、 $L2$ 、 \cdots 、 Lp 。例如, $L1$ 可以为“ $L11$ -数据中心- $L12$ 机房- $L13$ 机柜- $L14$ 节点- $L15$ 磁盘- $L16$ 文件路径- $L17$ 文件”。

(5) 步骤 S5: 将每个第一数据作为预设神经网络的输入, 以及将该第一数据对应的秘密子信息作为预设神经网络的输出, 对预设神经网络进行训练。

对上文所述的 p 个第一数据及对应的 p 个秘密子信息, 具体说明如下:

将第一数据 $D1$ 作为预设神经网络的输入, 将第一数据 $D1$ 对应的秘密子信息 $S1$ 作为预设神经网络的输出, 对预设神经网络进行训练;

将第一数据 $D2$ 作为预设神经网络的输入, 将第一数据 $D2$ 对应的秘密子信息 $S2$ 作为预设神经网络的输出, 对预设神经网络进行训练;

.....

将第一数据 Dp 作为预设神经网络的输入, 将第一数据 Dp 对应的秘密子信息 Sp 作为预设神经网络的输出, 对预设神经网络进行训练。

(6) 步骤 S6: 将每个第一数据输入训练后的神经网络, 将得到的输出作为对应的第一信息。

对上文所述的 p 个第一数据, 具体说明如下:

将第一数据 $D1$ 输入训练后的神经网络, 由该神经网络进行计算, 将得到的输出作为与第一数据 $D1$ 对应的第一信息 $T1$;

将第一数据 $D2$ 输入训练后的神经网络, 由该神经网络进行计算, 将得到的输出作为与第一数据 $D2$ 对应的第一信息 $T2$;

.....

将第一数据 D_p 输入训练后的神经网络, 由该神经网络进行计算, 将得到的输出作为与第一数据 D_p 对应的第一信息 T_p 。

(7) 步骤 S7: 将每个秘密子信息与对应的第一信息之间的差异作为对应的第二信息。

由于秘密子信息与第一数据之间是一一对应的关系, 而第一数据与第一信息之间也是一一对应的关系, 因此秘密子信息与第一信息之间也是一一对应的关系。

对上文所述的 p 个秘密子信息及对应的 p 个第一信息, 具体说明如下:

将秘密子信息 S_1 与对应的第一信息 T_1 之间的差异作为对应的第二信息 R_1 , $R_1 = S_1 - T_1$;

将秘密子信息 S_2 与对应的第一信息 T_2 之间的差异作为对应的第二信息 R_2 , $R_2 = S_2 - T_2$;

.....

将秘密子信息 S_p 与对应的第一信息 T_p 之间的差异作为对应的第二信息 R_p , $R_p = S_p - T_p$ 。

(8) 步骤 S8: 将多个第一位置、多个第一编号、多个第二信息及训练后的神经网络发送给拥有秘密信息访问权限的用户。

可以理解的是, 由于秘密子信息与第一数据之间是一一对应的关系, 而秘密子信息与第一编号一一对应, 第一数据与第一位置一一对应, 因此第一位置与第一编号之间也是一一对应的关系。而从步骤 S7 来看, 秘密子信息与第二信息之间也是一一对应的关系, 因此第一位置、第一编号和第二信息是相互对应的。

对上文所述的 p 个第一位置、对应的 p 个第一编号及对应的 p 个第二信息, 具体说明如下:

将相互对应的第一编号 W1、第一位置 L1、第二信息 R1；相互对应的第一编号 W2、第二位置 L2、第二信息 R2；……；相互对应的第一编号 Wp、第二位置 Lp、第二信息 Rp，以及训练后的神经网络发送给拥有秘密信息访问权限的用户。

4. 技术方案 4

如图 4-4 所示，本技术方案提供了一种信息提取方法，该方法与技术方案 3 的信息隐藏方法相对应，包括以下步骤：

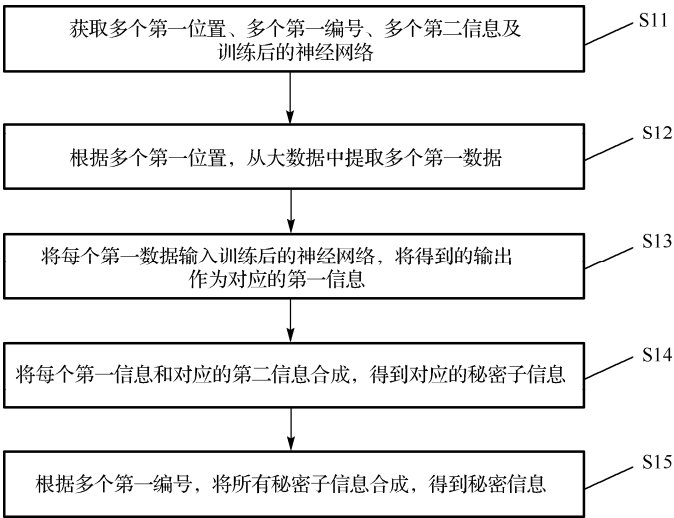


图 4-4 信息提取方法流程图

(1) 步骤 S11：获取多个第一位置、多个第一编号、多个第二信息及训练后的神经网络。

由于第一位置、第一编号和第二信息是相互对应的关系，因此拥有秘密信息访问权限的用户接收的是相互对应的第一编号 W1、第一位置 L1、第二信息 R1；相互对应的第一编号 W2、第一位置 L2、第二信息 R2；……；相互对应的第一编号 Wp、第一位置 Lp、第二信息 Rp，以及训练后的神经网络，并获取这些信息。

需要说明的是，因为对大数据拥有权限，但对秘密信息不拥有权限的用户不知道第一位置、第二信息、训练后的神经网络，所以无法通过大数据提取秘密信息，确保了秘密信息的安全性。

由于第一信息是以所述秘密信息为预期输出的神经网络的实际输出，因此第一信息与秘密信息的差异很小，第二信息的数据量很小；而神经网络是以网络权值的形式表示，其数据量也很小；所以只要将数据量很小的第一位置、第一编号、第二信息、训练后的深度学习神经网络发送给对拥有秘密信息访问权限的用户，就可以使用该用户从大数据中通过合成提取秘密信息，其网络开销、存储开销、计算开销都极低。

(2) 步骤 S12：根据多个第一位置，从大数据中提取多个第一数据。

由于第一位置与第一数据是一一对应的关系，通过第一位置可以从大数据中定位并提取对应的第一数据，具体如下：

通过第一位置 L1 定位并获取大数据中的第一数据 D1；

通过第一位置 L2 定位并获取大数据中的第一数据 D2；

.....

通过第一位置 Lp 定位并获取大数据中的第一数据 Dp。

(3) 步骤 S13：将每个第一数据输入训练后的神经网络，将得到的输出作为对应的第一信息。

由于在技术方案 3 的信息隐藏中，将每个第一数据输入训练后的神经网络，将得到的输出作为对应的第一信息。因此在本技术方案中，采用相同的方式，具体如下：

将第一数据 D1 输入训练后的深度学习，将得到的输出作为对应的第一信息 T1；

将第一数据 D2 输入训练后的深度学习，将得到的输出作为对应的第一信息 T2；

.....

将第一数据 D_p 输入训练后的深度学习，将得到的输出作为对应的第一信息 T_p 。

(4) 步骤 S14: 将每个第一信息和对应的第二信息合成，得到对应的秘密子信息。

由于在技术方案 3 的信息隐藏中，将每个秘密子信息与对应的第一信息之间的差异作为对应的第二信息，可知对应的第二信息 = 每个秘密子信息 - 对应的第一信息。也就是说，在本技术方案中，每个第一信息 + 对应的第二信息 = 对应的秘密子信息，所以将每个第一信息和对应的第二信息合成，即可恢复得到对应的秘密子信息，具体如下：

根据第一信息 T_1 和对应的第二信息 R_1 合成，得到对应的秘密子信息 S_1 ， $S_1 = T_1 + R_1$ ；

根据第一信息 T_2 和对应的第二信息 R_2 合成，得到对应的秘密子信息 S_2 ， $S_2 = T_2 + R_2$ ；

.....

根据第一信息 T_p 和对应的第二信息 R_p 合成，得到对应的秘密子信息 S_p ， $S_p = T_p + R_p$ 。

(5) 步骤 S15: 根据多个第一编号，将所有秘密子信息合成，得到秘密信息。

由于第一编号包含秘密子信息在秘密信息中的相对位置信息，即第一编号与秘密子信息是一一对应的关系，因此根据多个第一编号，可以将所有秘密子信息合成，得到秘密信息，具体如下：

第一编号 W_1 对应秘密子信息 S_1 ，第一编号 W_2 对应秘密子信息 S_2 ，……，第一编号 W_p 对应秘密子信息 S_p ，按照 W_1 、 W_2 、…、 W_p 的顺序，依次将 S_1 、 S_2 、…、 S_p 进行合成，得到秘密信息 S 。

5. 技术方案 5

如图 4-5 所示,本技术方案的信息隐藏方法在技术方案 3 的基础上,还包括以下步骤:

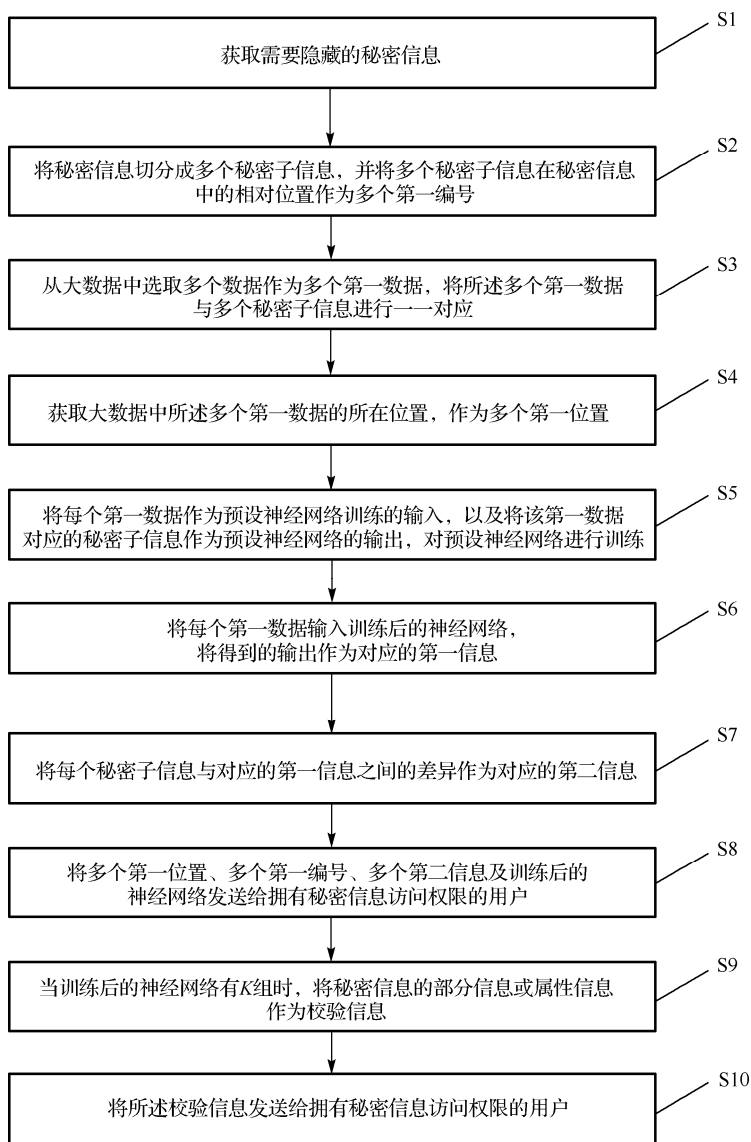


图 4-5 信息隐藏方法流程图

(1) 步骤 S9: 当训练后的神经网络有 K 组时, 将秘密信息的部分信息或属性信息作为校验信息。

其中, $K \geq 2$, 步骤 S2~S8 可以 K 次对同一个秘密信息 S 进行切分, 并插入大数据中(每次切分的方式、编号的方式、各个第一数据、预设神经网络可以不同), 从而得到 K 组训练后的神经网络及每组内的多个第一位置、多个第一编号、多个第二信息(第一位置、第一编号和第二信息相互对应)、 K 组训练后的神经网络及每组内的多个第一位置、多个第一编号、多个第二信息都发送给拥有秘密信息访问权限的用户, 将秘密信息的部分信息或属性信息作为校验信息, 例如, 校验信息可以为秘密信息 S 的字符个数。

(2) 步骤 S10: 将所述校验信息发送给拥有秘密信息访问权限的用户。

6. 技术方案 6

如图 4-6 所示, 本技术方案的信息提取方法与技术方案 5 的信息隐藏方法相对应, 在技术方案 4 的基础上, 还包括以下步骤:

(1) 步骤 S16: 当获取的训练后的神经网络有 K 组时, 在得到 K 组秘密信息后, 从 K 组秘密信息中选出与校验信息一致的秘密信息。

由于每组秘密信息都会通过步骤 S11~S15 进行处理, 因此最后可以得到 K 组秘密信息, 从 K 组秘密信息中选出与校验信息一致的秘密信息。例如, 当校验信息是秘密信息的字符个数时, 将 K 组秘密信息的字符个数与校验信息进行比较, 将一致的各组秘密信息选出。

(2) 步骤 S17: 当与校验信息一致的秘密信息为一组时, 将该组秘密信息发送给拥有秘密信息访问权限的用户。

(3) 步骤 S18: 当与校验信息一致的秘密信息多于一组时, 从与校验信息

一致的多组秘密信息中获取重复次数最多的秘密信息，并在重复次数最多的秘密信息中选出其中一组，发送给拥有秘密信息访问权限的用户。

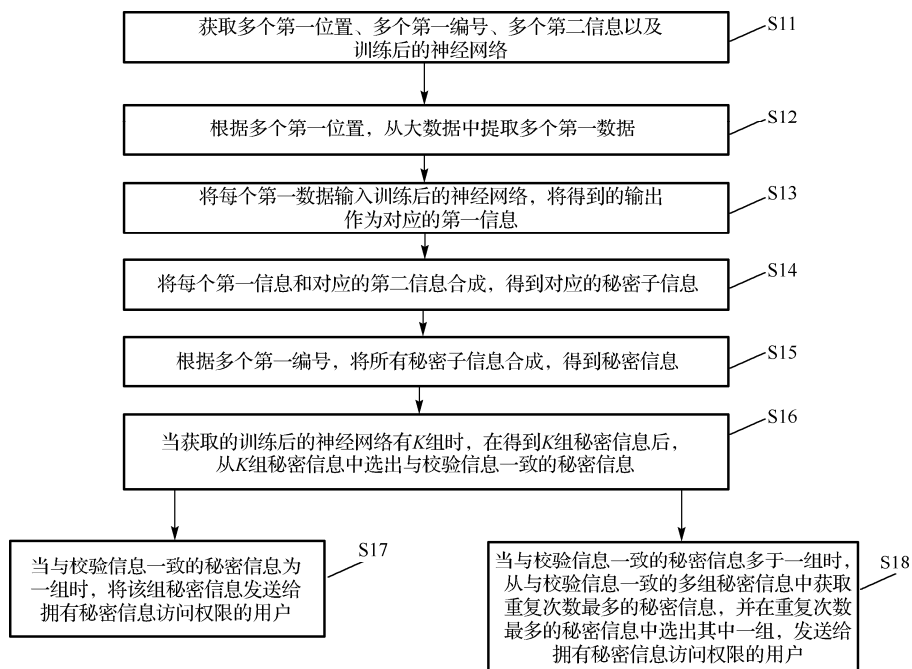


图 4-6 信息提取方法流程图

以 3 组与校验信息一致的秘密信息为例，如果 3 组秘密信息均不相同，说明最多的重复次数为 0，3 组秘密信息均为重复次数最多的秘密信息；如果 3 组秘密信息中，第 1 组和第 2 组秘密信息相同，第 3 组秘密信息与另外两组秘密信息不同，说明最多的重复次数为 1，则重复次数最多的秘密信息是第 1 组或第 2 组秘密信息；如果 3 组秘密信息都相同，说明最多的重复次数为 2，3 组秘密信息均为重复次数最多的秘密信息。

本技术方案以第 1 组和第 2 组秘密信息相同，第 3 组秘密信息与另外两组秘密信息不同为例，将第 1 组或第 2 组秘密信息发送给拥有秘密信息访问权限的用户。

4.1.3 基于大数据与深度学习的信息隐藏、提取系统

1. 技术方案 7

如图 4-7 所示，本技术方案提供了一种信息隐藏系统，该系统包括位置获取模块 1、秘密信息获取模块 2、训练模块 3、第一信息获取模块 4、第二信息获取模块 5 及发送模块 6，各个模块的具体功能如下：

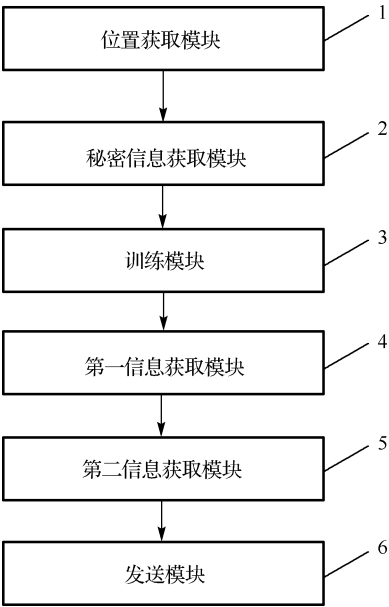


图 4-7 信息隐藏系统结构图

- (1)位置获取模块 1，用于获取大数据中第一数据所在位置。
- (2)秘密信息获取模块 2，用于获取第一数据中需要隐藏的秘密信息。
- (3)训练模块 3，用于将第一数据作为预设神经网络的输入，以及将秘密信息作为预设神经网络的输出，对预设神经网络进行训练。
- (4)第一信息获取模块 4，用于将第一数据输入训练后的神经网络，将得到的输出作为第一信息。

(5) 第二信息获取模块 5, 用于将秘密信息与第一信息之间的差异作为第二信息。

(6) 发送模块 6, 用于将大数据中第一数据所在位置、第二信息及训练后的神经网络发送给拥有秘密信息访问权限的用户。

2. 技术方案 8

如图 4-8 所示, 本技术方案提供了一种信息提取系统, 该系统与技术方案 7 中的信息隐藏系统相对应, 其包括获取模块 7、第一数据提取模块 8、第一信息获取模块 9 和合成模块 10, 各个模块的具体功能如下:




图 4-8 信息提取系统结构图

(1) 获取模块 7, 用于获取大数据中第一数据所在位置、第二信息及训练后的神经网络。

(2) 第一数据提取模块 8, 用于根据大数据中第一数据所在位置, 从大数据中提取第一数据。

(3) 第一信息获取模块 9, 用于将第一数据输入训练后的神经网络, 将得到的输出作为第一信息。

(4) 合成模块 10, 用于将第一信息和第二信息合成秘密信息。

3. 技术方案 9

如图 4-9 所示，本技术方案提供了一种信息隐藏系统，该系统包括秘密信息获取模块 1、切分模块 2、第一数据获取模块 3、位置获取模块 4、训练模块 5、第一信息获取模块 6、第二信息获取模块 7 和第一发送模块 8，各个模块的具体功能如下：

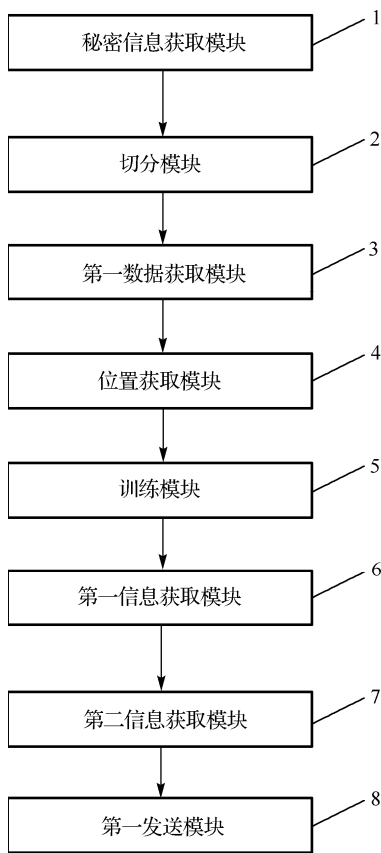


图 4-9 信息隐藏系统结构图

- (1)秘密信息获取模块 1，用于获取需要隐藏的秘密信息。
- (2)切分模块 2，用于将秘密信息切分成多个秘密子信息，并将多个秘密

子信息在秘密信息中的相对位置作为多个第一编号。

(3) 第一数据获取模块 3, 用于从大数据中选取多个数据作为多个第一数据, 将所述多个第一数据与多个秘密子信息进行一一对应。

(4) 位置获取模块 4, 用于获取大数据中所述多个第一数据的所在位置。

(5) 训练模块 5, 用于将每个第一数据作为预设神经网络的输入, 以及将该第一数据对应的秘密子信息作为预设神经网络的输出, 对预设神经网络进行训练。

(6) 第一信息获取模块 6, 用于将每个第一数据输入训练后的神经网络, 将得到的输出作为对应的第一信息。

(7) 第二信息获取模块 7, 用于将每个秘密子信息与对应的第一信息之间的差异作为第二信息。

(8) 第一发送模块 8, 用于将大数据中所述多个第一数据的所在位置、多个第一编号、多个第二信息及训练后的神经网络, 发送给拥有秘密信息访问权限的用户。

4. 技术方案 10

如图 4-10 所示, 本技术方案提供了一种信息提取系统, 该系统与技术方案 9 的信息隐藏系统相对应, 其包括获取模块 11、第一数据提取模块 12、第一信息获取模块 13、第一合成模块 14 和第二合成模块 15, 各个模块的具体功能如下:

(1) 获取模块 11, 用于获取大数据中所述多个第一数据的所在位置、多个第一编号、多个第二信息及训练后的神经网络。

(2) 第一数据提取模块 12, 用于根据大数据中所述多个第一数据的所在位置, 从大数据中提取多个第一数据。

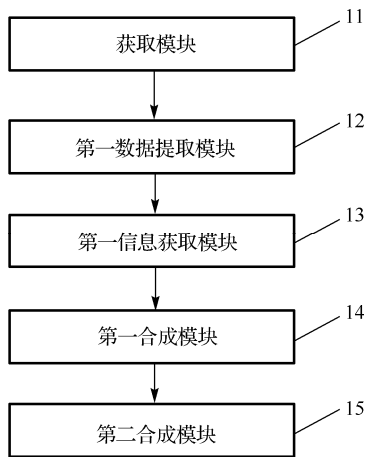


图 4-10 信息提取系统结构图

(3) 第一信息获取模块 13, 用于将每个第一数据输入训练后的神经网络, 将得到的输出作为对应的第一信息。

(4) 第一合成模块 14, 用于将每个第一信息和对应的第二信息合成, 得到对应的秘密子信息。

(5) 第二合成模块 15, 用于根据多个第一编号, 将所有秘密子信息合成, 得到秘密信息。

5. 技术方案 11

如图 4-11 所示, 本技术方案的信息隐藏系统在技术方案 9 的基础上, 还包括校验信息获取模块 9 和第二发送模块 10, 这两个模块的具体功能如下:

(1) 校验信息获取模块 9, 用于当训练后的神经网络有 K 组时, 将秘密信息的部分信息或属性信息作为校验信息, 其中, $K \geq 2$ 。

(2) 第二发送模块 10, 用于将所述校验信息发送给拥有秘密信息访问权限的用户。

6. 技术方案 12

如图 4-12 所示, 本技术方案的信息提取系统与技术方案 11 的信息隐藏

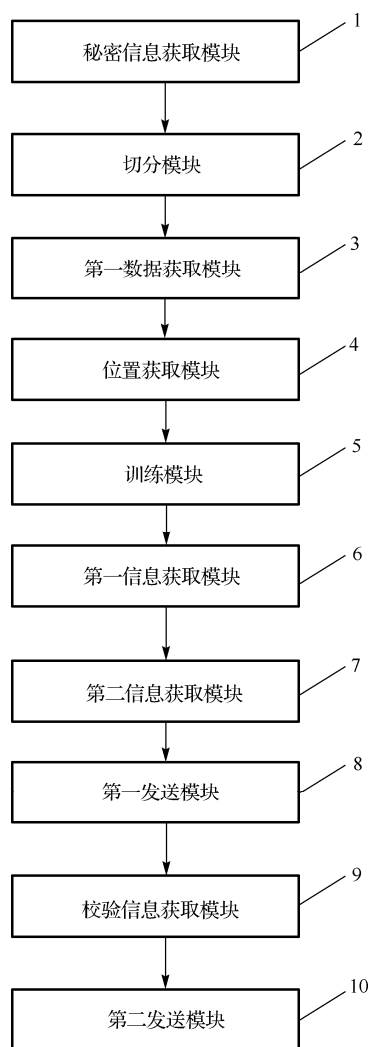


图 4-11 信息隐藏系统结构图

系统相对应，在技术方案 10 的基础上，还包括秘密信息选取模块 16、第一发送模块 17 和第二发送模块 18，这 3 个模块的具体功能如下：

(1) 秘密信息选取模块 16，用于当获取的训练后的神经网络有 K 组时，在得到 K 组秘密信息后，从 K 组秘密信息中选出与校验信息一致的秘密信息，其中， $K \geq 2$ 。

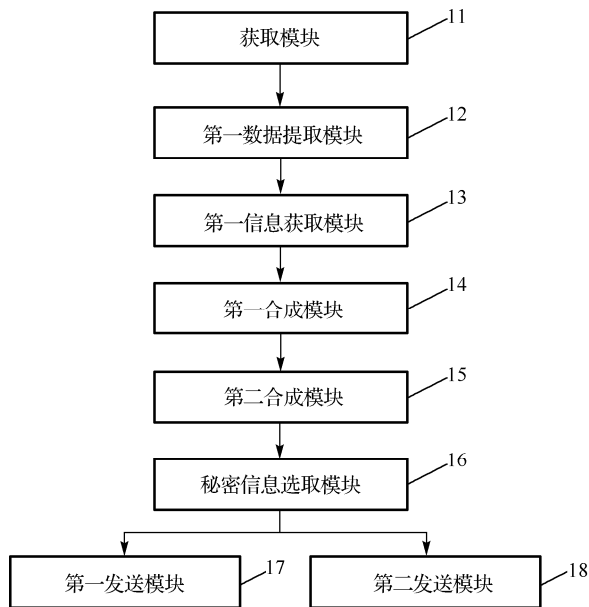


图 4-12 信息提取系统结构图

(2) 第一发送模块 17，用于当与校验信息一致的 secret 信息为一组时，将该组 secret 信息发送给拥有 secret 信息访问权限的用户。

(3) 第二发送模块 18，用于当与校验信息一致的 secret 信息多于一组时，从与校验信息一致的多组 secret 信息中获取重复次数最多的 secret 信息，并在重复次数最多的 secret 信息中选出其中一组，发送给拥有 secret 信息访问权限的用户。

4.2 基于大数据与深度学习的婚恋对象匹配数据处理方法和系统

4.2.1 研究现状

大数据是需要新的处理模式才能具有更强的决策力、洞察发现力和流程优化能力的海量、高增长率和多样化的信息资产^[36-41]。在日常生活中可以发

现，夫妻往往是有夫妻相的，因为人的长相与基因相关，而基因与人的性格等方面相关。

目前，很多婚介机构或网站向用户随机推荐婚恋对象，没有客观依据，不能预测待推荐对象与请求匹配对象在未来时间范围内的匹配状态。

基于此，有必要针对上述问题，提供一种婚恋对象匹配数据处理方法和系统。基于大数据和深度学习建立待匹配对象与预设匹配时长的相关性，提供客观的匹配依据，能预测待推荐对象与请求匹配对象在未来时间范围内的匹配状态。获取待匹配的第一对象图像数据和第二对象图像数据，将第一对象图像数据和第二对象图像数据输入已训练的深度学习神经网络，神经网络的参数是以已婚匹配对象对应的匹配图像大数据作为输入，将已婚匹配对象对应的有效匹配时长与深度学习神经网络训练模型的预设匹配时长比较得到的对应的标签作为预期输出，通过深度学习神经网络训练模型训练得到。获取已训练的深度学习神经网络输出的对应的匹配结果，根据匹配结果确定第一对象与第二对象在所述预设匹配时长的范围内的匹配状态。基于大数据和深度学习建立待匹配对象与预设匹配时长的相关性，提供客观的匹配依据，能预测待推荐对象与请求匹配对象在未来时间范围内的匹配状态。

4.2.2 基于大数据与深度学习的婚恋对象匹配数据处理方法

如图 4-13、图 4-14 所示，在本技术方案中，提出了一种婚恋对象匹配数据处理方法，包括初始化配置和数据处理两部分，具体包括以下步骤：

(1) 步骤 S1：获取训练图像大数据，训练图像大数据包括已婚匹配对象对应的匹配图像大数据，从匹配图像大数据中提取对应的各个已婚匹配对象对应的匹配图像对。

其中，训练图像大数据是指用于训练深度学习神经网络的海量数据，其中，已婚匹配对象对应的匹配图像大数据包括多个不同地区的已婚匹配对象

双方对应的图像数据，如已婚对象双方的照片。可以理解的是，可以针对不同地区分别采用对应地区的训练图像大数据，训练得到与地区对应的深度学习神经网络，因为不同的地区，由于地域、人口、风俗文化的差异，在对象匹配度上也存在差异，针对不同地区形成不同的深度学习神经网络，有利于提高当地的匹配客观性与准确率。

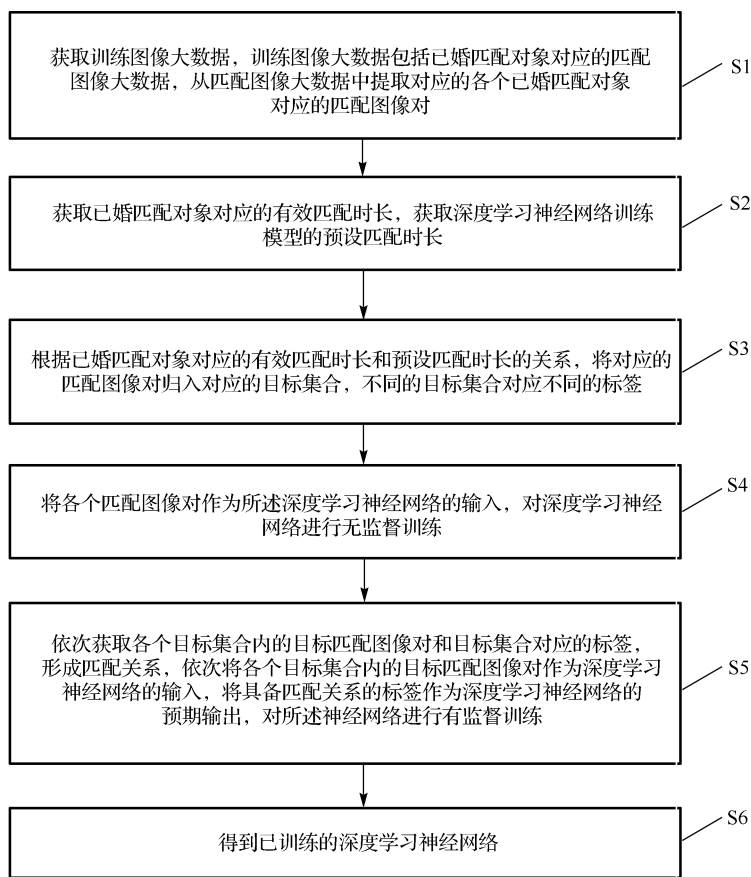


图 4-13 初始化配置的流程图

另外，匹配图像对是指已婚匹配对象双方的图像，可为人脸图像、全身图像等，可根据需要自定义需要的图像范围。可通过人脸识别算法提取人脸，

得到各个已婚匹配对象对应的匹配图像对。如已婚匹配对象包括 A 、 B 、 C 、 D ，则匹配图像对分别为 $\{A_1, A_2\}$ ， $\{B_1, B_2\}$ ， $\{C_1, C_2\}$ ， $\{D_1, D_2\}$ 。

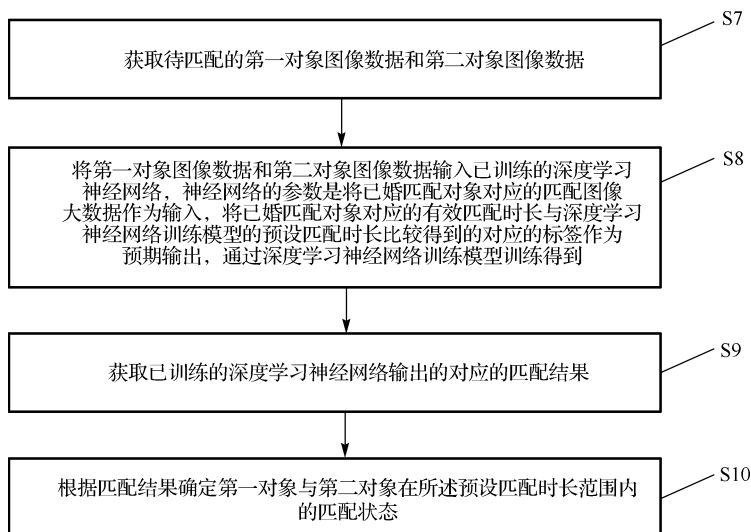


图 4-14 婚恋对象匹配数据处理方法的流程图

例如，匹配图像大数据是结婚证数据，在结婚证中根据性别特征和人脸特征进行图像识别，提取丈夫照片和妻子照片，形成各个已婚匹配对象对应的匹配图像对；也可以利用丈夫照片和妻子照片在结婚证中的预设位置，根据位置范围对丈夫照片和妻子照片进行直接提取（因为结婚证都是标准的，丈夫照片在结婚证的固定位置范围内，妻子照片也在结婚证的另一固定位置范围内，可快速提取得到匹配图像对，提高数据准备的效率）。

(2) 步骤 S2：获取已婚匹配对象对应的有效匹配时长，获取深度学习神经网络训练模型的预设匹配时长。

具体地，已婚匹配对象对应的有效匹配时长可由法定匹配状态文件中的法定日期确定，其中，法定日期包括匹配起始日期、匹配终止日期等。对于已婚匹配对象中双方出现异常情况的，可根据异常情况确定有效匹配时长，

如已婚匹配对象中存在死亡、失踪等情况的,可根据异常情况出现的时间确定有效匹配时长。深度学习神经网络训练模型的预设匹配时长是在训练深度学习神经网络训练模型时就确定的,可训练得到对应的不同预设匹配时长的深度学习神经网络训练模型,然后根据需要进行选择目标预设匹配时长的训练模型。

(3)步骤 S3: 根据已婚匹配对象对应的有效匹配时长和预设匹配时长的关系,将对应的匹配图像对归入对应的目标集合,不同的目标集合对应不同的标签。

具体地,可获取预设的包含两个变量的函数计算关系,将有效匹配时长和预设匹配时长分别作为两个变量对应的值代入,计算得到结果,根据结果将对应的匹配图像对归入对应的目标集合,其中,不同的目标集合对应不同的标签。在本技术方案中,先预设多个区间段,不同的区间段对应不同的目标集合,有对应的标签,确定有效匹配时长和预设匹配时长差值所在的区间段,从而将对应的匹配图像对归入所在区间段对应的目标集合。

(4)步骤 S4: 将各个匹配图像对作为所述深度学习神经网络的输入,对深度学习神经网络进行无监督训练。

具体地,将各个匹配图像对,如 $\{A_1, A_2\}$, $\{B_1, B_2\}$, $\{C_1, C_2\}$, $\{D_1, D_2\}$ 分别输入深度学习神经网络,进行无监督训练。采用自下而上的无监督训练方法,逐层构建单层神经元,每层采用 wake-sleep 算法进行调优。每次仅调整一层,逐层调整,这个过程可视为一个 feature learning 的过程,是和传统深度学习方法区别较大的部分。其中, wake-sleep 算法分为 wake 阶段和 sleep 阶段, wake 阶段是认知过程,通过下层的输入特征(Input)和向上的认知权重(Encoder)产生每层的抽象表示(Code),再通过当前的生成权重(Decoder)产生一个重建信息(Reconstruction),计算输入特征和重建信息的残差,使用梯度下降法修改层间的下行生成权重(Decoder)。也就是说,“如果现实跟我

想象得不一样，那么改变我的生成权重使我想象的东西变得与现实一样。”sleep 阶段是生成过程，通过上层概念(Code)和向下的生成权重(Decoder)，生成下层的状态，再利用认知权重(Encoder)产生一个抽象景象。利用初始上层概念和新建抽象景象的残差，使用梯度下降法修改层间向上的认知权重。也就是说，“如果梦中的景象不是我脑中的相应概念，那么改变我的认知权重使这种景象在我看来就是这个概念。”

(5)步骤 S5: 依次获取各个目标集合内的目标匹配图像对和目标集合对应的标签，形成匹配关系，依次将各个目标集合内的目标匹配图像对作为深度学习神经网络的输入，将具备匹配关系的标签作为深度学习神经网络的预期输出，对所述神经网络进行有监督训练。

具体地，具备匹配关系的标签是各个目标集合内的目标匹配图像对对应的标签，表示匹配图像对中的两张照片对应的对象在预设匹配时长范围内的匹配状态。如将各个目标集合表示为 P_i ，其中 $1 \leq i \leq N$ ， N 表示目标集合的总数。各个目标集合对应的标签分别为 M_i ，获取 P_i 集合内的目标匹配图像对作为深度学习神经网络的输入，将对应的 M_i 作为深度学习神经网络的预期输出，进行有监督训练。

自顶向下的有监督训练，这一步是在第一步学习获得各层参数的基础上进行的，在最顶层的编码层添加一个分类器，如罗杰斯特回归、SVM 等，然后通过带标签数据的有监督训练，利用梯度下降法微调整个网络参数。深度学习神经网络的第一步实质上是一个网络参数初始化的过程，区别于传统的初值随机初始化。深度学习神经网络是通过无监督训练输入数据的结构得到的，因此这个初值更接近全局最优，从而能够取得更好的效果。

(6)步骤 S6: 得到已训练的深度学习神经网络。

经过上面的无监督训练和有监督训练后，得到已训练的深度学习神经网络。

(7) 步骤 S7: 获取待匹配的第一对象图像数据和第二对象图像数据。

其中, 第一对象图像数据、第二对象图像数据是分别表征第一对象和第二对象特征的数据, 可以是拍摄的照片, 也可以是对照片进行特征提取后的图像特征数据。其中, 第一对象和第二对象分别为请求匹配对象和待推荐对象。第一对象图像数据、第二对象图像数据可以携带在终端发送的匹配请求中, 也可以是从服务器中获取的。在本技术方案中, 第二对象图像数据是从服务器存储的注册用户对应的图像信息中提取的图像数据, 随着注册用户信息更新。第一对象图像数据和第二对象图像数据分别是从第一对象图像和第二对象图像中提取人脸区域得到的。

(8) 步骤 S8: 将第一对象图像数据和第二对象图像数据输入已训练的深度学习神经网络, 神经网络的参数是将已婚匹配对象对应的匹配图像大数据作为输入, 将已婚匹配对象对应的有效匹配时长与深度学习神经网络训练模型的预设匹配时长比较得到的对应的标签作为预期输出, 通过深度学习神经网络训练模型训练得到。

其中, 深度学习神经网络是模拟人脑进行分析学习的神经网络, 模仿人脑的机制来解释图像数据。在本技术方案中, 将卷积神经网络 (Convolutional Neural Networks, CNN) 作为此深度学习神经网络, 卷积神经网络是在多层神经网络的基础上发展起来的针对图像分类和识别而特别设计的一种深度学习方法。

其中, 已训练的神经网络的参数, 是以已婚匹配对象对应的匹配图像大数据作为输入, 将已婚匹配对象对应的有效匹配时长与深度学习神经网络训练模型的预设匹配时长比较得到的对应的标签作为预期输出, 输入深度学习神经网络训练模型训练得到。已训练的深度学习神经网络包括输入层、多个隐层和输出层, 其中层数、每层预设节点数、各网络连接的权值由训练得到。

其中,已婚匹配对象是指法定效力内的结婚登记对象,获取数据量足够大的已婚匹配对象对应的匹配图像大数据作为深度学习神经网络的训练数据进行训练,得到神经网络的参数。有效匹配时长是指法定效力内的匹配时长,可根据已婚匹配对象双方的生命状态和法定效力内的匹配状态进行确定。深度学习神经网络训练模型的预设匹配时长是根据需要自定义的,如定义为一生或30年等。将有效匹配时长与深度学习神经网络训练模型的预设匹配时长比较,可得到不同的比较结果,不同的比较结果对应不同的标签,将得到的训练时输入数据对应的匹配的标签作为预期输出,从而进行训练。其中,标签用于描述预设匹配时长范围内的匹配度,匹配度可以是匹配概率、匹配是否成功等。

在本技术方案中,匹配对象对应的匹配图像大数据包括已婚匹配对象双方的人脸照片,或双方所在的地域、结婚登记地域、年龄信息,形成多维度的输入数据进行训练。可针对不同结婚登记地区生成对应的不同的已训练的深度学习神经网络,提高不同地区对象匹配的适应度与准确性。

由于法定效力内的结婚登记对象代表匹配成功,根据匹配成功对象的图像信息,形成客观的、有科学依据的大数据,进行深度网络分析,提高了匹配对象的客观依据性。

(9)步骤 S9: 获取已训练的深度学习神经网络输出的对应的匹配结果。

具体地,深度学习神经网络输出的匹配结果形式不限,可以是匹配概率,也可以是互斥的匹配标签,如用1表示第一对象与第二对象在预设匹配时长范围内匹配成功,用0表示匹配失败。已训练的深度学习神经网络可以根据输入的待匹配对象的图像数据分析,输出对应的、客观的匹配结果。

(10)步骤 S10: 根据匹配结果确定第一对象与第二对象在所述预设匹配时长范围内的匹配状态。

具体地,如果匹配结果是匹配概率,则可根据匹配概率的大小确定第一

对象与第二对象在预设匹配时长范围内的匹配概率。如果匹配结果是互斥的匹配标签，则直接根据匹配标签的值，得到第一对象与第二对象在预设匹配时长范围内的匹配状态，如匹配成功或匹配失败。可将第一对象与多个待匹配对象进行预设匹配时长范围内的匹配状态的计算，获取最大匹配概率的对象作为目标匹配对象。

1. 步骤 S2

在本技术方案中，如图 4-15 所示，在步骤 S2 中，获取已婚匹配对象对应的有效匹配时长的具体步骤包括：

(1) 步骤 S2-1：获取已婚匹配对象的匹配起始时间和当前匹配状态，判断当前匹配状态是否匹配。如果为否，则进入步骤 S2-2；如果为是，则进入步骤 S2-3。

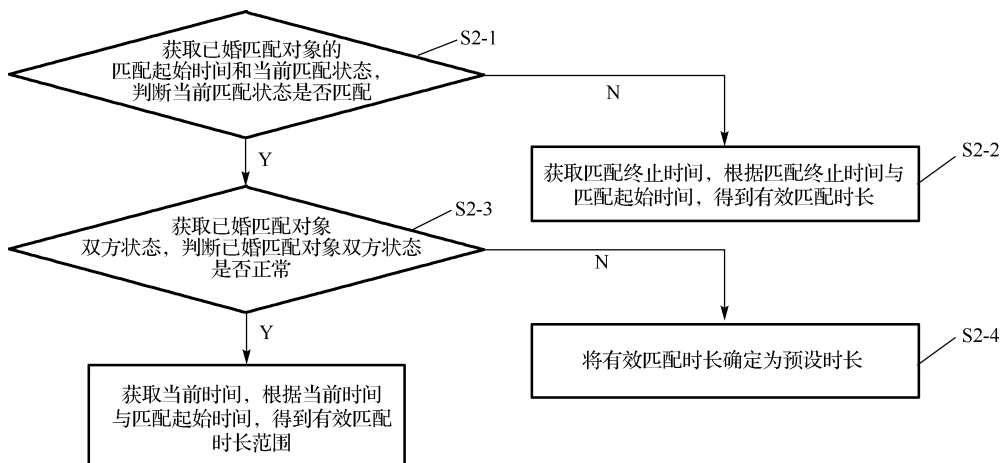


图 4-15 步骤 S2 的流程图

具体地，匹配起始时间是由法定匹配文件确定的匹配开始的有效时间，当前匹配状态是根据法定匹配文件确定的已婚匹配对象双方在当前时间对应的匹配状态，包括匹配状态和非匹配状态。如通过结婚证上的结婚日期得到

匹配起始时间，如果在当前时间下还是结婚状态，则当前匹配状态为匹配，若在当前时间下处于离婚状态，则当前匹配状态为非匹配。

(2) 步骤 S2-2: 获取匹配终止时间，根据匹配终止时间与匹配起始时间，得到有效匹配时长。

具体地，匹配终止时间是由法定匹配文件确定的匹配结束的有效时间，如当前匹配状态为非匹配，则从离婚证上获取离婚日期，得到匹配终止时间。将离婚日期与结婚日期相减，得到有效匹配时长。

(3) 步骤 S2-3: 获取已婚匹配对象双方状态，判断已婚匹配对象双方状态是否正常。如果双方状态正常，则获取当前时间，根据当前时间与匹配起始时间，得到有效匹配时长范围；否则，进入步骤 S2-4。

具体地，已婚匹配对象双方状态正常是指已婚匹配对象双方不存在丧偶的情况，且仍然处于匹配状态，将当前时间日期减去匹配起始时间，得到当前匹配时长；有效匹配时长大于当前匹配时长。如结婚的日期为 1997-9-20，未离婚，双方正常，当前日期为 2017-9-20，则有效匹配时长大于 20 年。

(4) 步骤 S2-4: 将有效匹配时长确定为预设时长。

具体地，如果已婚匹配对象双方中存在丧偶的情况，则将有效匹配时长确定为预设时长，其中，预设时长可根据需要自定义，如定义为一生，或根据丧偶的时间进行确定。

在本技术方案中，通过当前匹配状态和已婚匹配对象双方状态，确定对应的有效匹配时长，能灵活准确地确定有效匹配时长范围。

2. 步骤 S3

在本技术方案中，如图 4-16 所示，步骤 S3 具体包括：

(1) 步骤 S3-1: 如果有效匹配时长大于或等于预设匹配时长，则将已婚匹配对象对应的匹配图像对归入第一集合，所述第一集合对应第一标签。

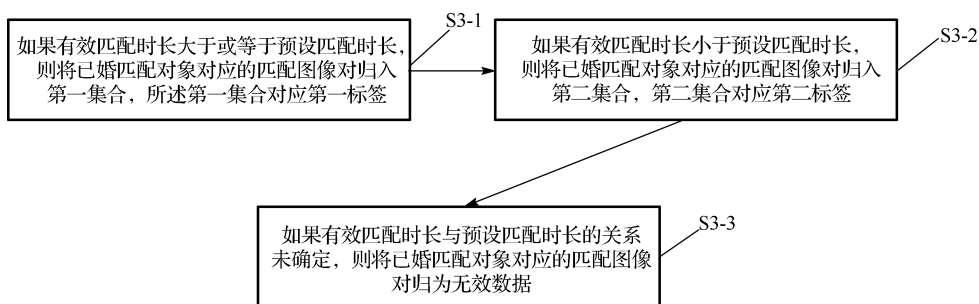


图 4-16 步骤 S3 的流程图

具体地，同一集合中的匹配图像对具有相同的匹配特征，其中，第一集合中的匹配图像对对应的特征是有有效匹配时长大于或等于预设匹配时长，说明第一集合中的各个匹配图像对对应的匹配对象在预设匹配时长内属于匹配状态，从而第一标签表示匹配对象在预设匹配时长内属于匹配状态。第一标签的具体值可根据需要自定义，如定义为 1。

(2) 步骤 S3-2：如果有有效匹配时长小于预设匹配时长，则将已婚匹配对象对应的匹配图像对归入第二集合，第二集合对应第二标签。

具体地，第二集合中的匹配图像对对应的特征是有有效匹配时长小于预设匹配时长，说明第二集合中的各个匹配图像对对应的匹配对象没有在预设匹配时长内属于匹配状态，从而第二标签表示匹配对象在预设匹配时长内属于非匹配状态。第二标签的具体值可根据需要自定义，如定义为 0。

(3) 步骤 S3-3：如果有有效匹配时长与预设匹配时长的关系未确定，则将已婚匹配对象对应的匹配图像对归为无效数据。

具体地，对于有效匹配时长与预设匹配时长的关系未确定的匹配图像对不归入任何一个集合，成为无效数据，从而进一步提高了训练数据的准确性，保证训练好的深度学习神经网络进行预测的准确度。

3. 步骤 S7

在本技术方案中，步骤 S7 包括：接收请求匹配对象用户终端发送的匹配

请求，匹配请求包括请求匹配对象图像数据，将匹配对象图像数据作为第一对象图像数据，将获取的待推荐对象图像数据作为第二对象图像数据。

具体地，请求匹配对象是指需要进行匹配的对象，请求匹配对象图像数据是指请求匹配对象的图片或根据图片提取的特征数据，待推荐对象是指与请求匹配对象进行匹配的候选对象。待推荐对象图像数据是与请求匹配对象进行匹配的候选对象的图片或根据图片提取的特征数据。匹配请求中，可以直接携带待推荐对象图像数据，也可以从服务器中获取待推荐对象图像数据。待推荐对象图像数据可以根据待推荐对象的更新而动态更新。

例如，从婚恋匹配网站获取注册用户的资料图片形成待推荐对象图像数据，可根据请求匹配对象的基本资料筛选待推荐对象。

4. 步骤 10

在本技术方案中，步骤 S10 包括：如果匹配结果为第一标签，则确定第一对象与第二对象在预设匹配时长的范围内为匹配成功状态，如果匹配结果为第二标签，则确定第一对象与第二对象在预设匹配时长的范围内为匹配失败状态。

具体地，根据已训练的深度学习神经网络输出的匹配结果与预设标签是否相同，判断第一对象与第二对象在预设匹配时长范围内的匹配状态，可直接得出匹配结果，简单方便。第一标签和第二标签的格式可根据需要自定义，如用标志位表示，1 表示第一标签，0 表示第二标签。

步骤 S10 之后，还包括：如果请求匹配对象与待推荐对象在预设匹配时长范围内的匹配状态为匹配成功，则向请求匹配对象用户终端发送待推荐对象对应的用户信息。

具体地，如果请求匹配对象与待推荐对象在预设匹配时长范围内的匹配状态为匹配成功，则说明请求匹配对象与待推荐对象的匹配关系稳定，将待

推荐对象对应的用户信息推送至请求匹配对象用户终端。只有请求匹配对象与待推荐对象的匹配关系稳定，才会进行推送，提高了请求匹配对象获取待推荐对象的有效性与客观性，提高了请求匹配对象的感兴趣度，提高了匹配效率，避免大量无效的待推荐对象的推送对用户形成干扰。

4.2.3 基于大数据与深度学习的婚恋对象匹配数据处理系统

在本技术方案中，如图 4-17 所示，提供了一种婚恋对象匹配数据处理系统，具体包括：

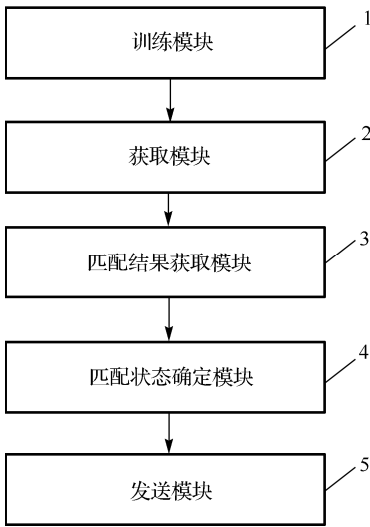


图 4-17 婚恋对象匹配数据处理系统的结构图

(1) 训练模块 1，用于获取训练图像大数据。训练图像大数据包括已婚匹配对象对应的匹配图像大数据，从匹配图像大数据中提取对应的各个已婚匹配对象对应的匹配图像对，获取已婚匹配对象对应的有效匹配时长，获取深度学习神经网络训练模型的预设匹配时长。根据已婚匹配对象对应的有效匹

配时长和预设匹配时长的关系，将对应的匹配图像对归入对应的目标集合。不同的目标集合对应不同的标签，将各个匹配图像对作为深度学习神经网络的输入，对深度学习神经网络进行无监督训练，依次获取各个目标集合内的目标匹配图像对和目标集合对应的标签形成匹配关系。依次将各个目标集合内的目标匹配图像对作为深度学习神经网络的输入，将具备匹配关系的标签作为深度学习神经网络的预期输出，对深度学习神经网络进行有监督训练，得到已训练的深度学习神经网络。

训练模块 1 还可用于获取已婚匹配对象的匹配起始时间和当前匹配状态，如果当前匹配状态为非匹配，则获取匹配终止时间，根据匹配终止时间与匹配起始时间得到有效匹配时长。如果当前匹配状态为匹配，则获取已婚匹配对象双方状态；如果已婚匹配对象双方状态正常，则获取当前时间，根据当前时间与匹配起始时间得到有效匹配时长范围；如果已婚匹配对象双方中至少一方状态异常，则将有效匹配时长确定为预设时长。

训练模块 1 还可用于如果有效匹配时长大于或等于预设匹配时长，则将已婚匹配对象对应的匹配图像对归入第一集合，第一集合对应第一标签。如果有效匹配时长小于预设匹配时长，则将已婚匹配对象对应的匹配图像对归入第二集合，第二集合对应第二标签，如果有效匹配时长与预设匹配时长的关系未确定，则将已婚匹配对象对应的匹配图像对归为无效数据。

(2) 获取模块 2，用于获取待匹配的第一对象图像数据和第二对象图像数据。

获取模块 2 还用于接收请求匹配对象用户终端发送的匹配请求，匹配请求包括：请求匹配对象图像数据，将匹配对象图像数据作为第一对象图像数据，将获取的待推荐对象图像数据作为第二对象图像数据。

(3) 匹配结果获取模块 3, 用于将第一对象图像数据和第二对象图像数据输入已训练的深度学习神经网络, 深度学习神经网络的参数是以已婚匹配对象对应的匹配图像大数据作为输入, 将已婚匹配对象对应的有效匹配时长与深度学习神经网络训练模型的预设匹配时长比较, 将得到的对应的标签作为预期输出, 通过深度学习神经网络训练模型训练得到, 获取所述已训练的深度学习神经网络输出的对应的匹配结果。

(4) 匹配状态确定模块 4, 用于根据匹配结果确定第一对象与第二对象在预设匹配时长范围内的匹配状态。

匹配状态确定模块 4 还用于如果匹配结果为第一标签, 则确定第一对象与第二对象在所述预设匹配时长的范围内为匹配成功状态, 如果匹配结果为第二标签, 则确定第一对象与第二对象在预设匹配时长范围内为匹配失败状态。

(5) 发送模块 5, 用于如果请求匹配对象与待推荐对象在预设匹配时长范围内的匹配状态为匹配成功状态, 则向请求匹配对象用户终端发送待推荐对象对应的用户信息。

第5章 深度学习的大数据智能诊断应用

本章给出了两种深度学习的大数据智能诊断应用：基于深度学习的面向自动诊断的医疗数据处理方法和系统，基于双深度学习的数据处理方法和疾病诊断装置。

5.1 基于深度学习的面向自动诊断的医疗数据处理方法和系统

本节研究了一种医疗数据处理方法和系统，该系统包括体检数据采集设备和数据服务器；体检数据采集设备用于获取覆盖待确诊患者身体各部分的第一体检数据，并将第一体检数据发送给数据服务器；数据服务器用于利用深度学习神经网络对第一体检数据进行运算，得到第一体检数据对应的确诊结果。深度学习神经网络是根据覆盖已确诊患者身体各部分的第二体检数据和第二体检数据对应的确诊数据训练得到的。本节提供的医疗数据处理方法和系统，在确诊结果的生成过程中，无须耗费过多时间进行各项身体检查，也无须医生对各项检查结果进行详细研究，只需在接收到体检数据采集设备发送的第一体检数据后，利用深度学习神经网络进行运算，即可得到确诊结果，提高了确诊结果的生成效率，进而辅助医生更加快速、准确、合理地做出诊断。

5.1.1 研究现状

随着计算机技术的发展,大多数医院已经利用计算机来记录患者的医疗数据,并将医疗数据存储到服务器中。每天都有大量的患者到医院就诊,医生则将每个患者在就诊过程中产生的医疗数据存储到服务器中。

然而,在将医疗数据存储到服务器后,大量的医疗数据需要占用较多的存储空间,这些空间没有得到充分的利用。同时,患者到医院就诊时,需要耗费大量时间进行各种类型的身体检查,医生也需要耗费时间对各种检查的结果进行详细研究,才能确诊,从而得到确诊结果,患者确诊结果的生成效率较低。可见,计算机辅助诊断尤为重要^[42-53]。

基于此,有必要针对患者确诊结果生成效率较低的问题,提供一种医疗数据处理方法和系统。通过该系统获取待确诊患者的第一体检数据。其中,第一体检数据是覆盖待确诊患者身体的各部分,并可以全面反映患者身体的健康状况的数据。根据覆盖已确诊患者身体各部分的第二体检数据训练得到的深度学习神经网络,对覆盖待确诊患者身体各部分的第一体检数据进行运算,通过深度学习神经网络的运算,来得到第一体检数据对应的确诊结果。

5.1.2 基于深度学习的面向自动诊断的医疗数据处理方法

如图 5-1 所示,在本技术方案中,提供了一种医疗数据处理方法,该方法具体包括以下步骤:




图 5-1 医疗数据处理方法的流程图

(1) 步骤 S1: 获取覆盖待确诊患者身体各部分的第一体检数据。

(2) 步骤 S2: 利用深度学习神经网络对第一体检数据进行运算, 得到第一体检数据对应的确诊结果; 该深度学习神经网络是根据覆盖已确诊患者身体各部分的第二体检数据和第二体检数据对应的确诊数据训练得到的。

在步骤 S1 之前还包括训练所述深度学习神经网络的步骤, 具体步骤如下: 获取第二体检数据; 将第二体检数据对应的已确诊患者的确诊数据进行关联存储到医疗数据库中; 从医疗数据库中提取关联的第二体检数据和第二体检数据对应的确诊数据; 根据提取到的第二体检数据和第二体检数据对应的确诊数据训练得到深度学习神经网络。

步骤 S2 之后还包括确诊报告的生成步骤, 具体步骤如下: 根据确诊结果确定异常体检指标; 在第一体检数据中提取异常体检指标对应的数值; 根据异常体检指标对应的数值和确诊结果生成确诊报告。

具体地, 步骤 S2 还包括指标数值的编码步骤, 具体如下: 提取第一体检数据中各体检指标的数值; 分别对各体检指标的数值进行编码, 生成各体检指标对应的编码数据, 编码数据包括指标标识和指标数值; 将编码数据输入深度学习神经网络, 使神经网络将编码数据输入与编码数据中指标标识对应的节点进行运算, 得到运算结果; 根据运算结果确定第一体检数据对应的疾病名称。

步骤 S2 还包括标准化处理步骤, 具体如下: 提取第一体检数据中各体检指标的数值; 对各体检指标的数值进行标准化处理, 得到各体检指标的标准化值; 将各体检指标的标准化值输入深度学习神经网络, 使神经网络将各体检指标的标准化值输入相应的节点, 并根据节点之间的权重值对各体检指标的标准化值进行运算, 得到第一体检数据对应的确诊结果。

5.1.3 基于深度学习的面向自动诊断的医疗数据处理系统

如图 5-2、图 5-3 所示，在本技术方案中，提供了一种医疗数据处理系统，该系统包括神经网络训练和医疗数据处理两部分。

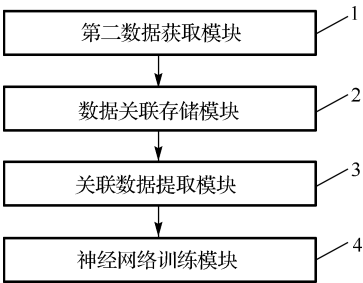


图 5-2 神经网络训练系统的结构图

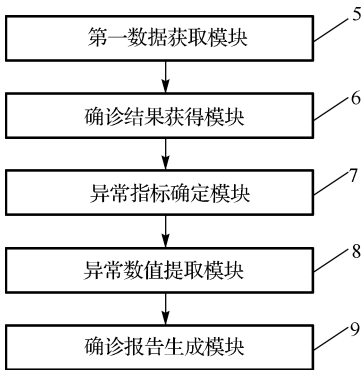


图 5-3 医疗数据处理系统的结构图

(1) 第二数据获取模块 1，用于获取第二体检数据。

具体地，利用医疗扫描设备对已确诊患者身体部分进行扫描，获取已确诊患者的第二体检数据。具体可以是对已确诊患者身体进行覆盖身体各部分的扫描，得到已确诊患者的医疗图像，提取医疗图像中的特征区域进行分析，得到已确诊患者的覆盖身体各部分的第二体检数据。医疗图像具体可以是 CT(Computed Tomography，X 线计算机断层摄影) 图像，B 超(B-mode

Ultrasonography)图像和MRI(Magnetic Resonance Imaging, 磁共振成像)图像中的至少一种。体检数据采集设备将第二体检数据发送给数据服务器。

(2)数据关联存储模块2,用于将第二体检数据对应的已确诊患者的确诊数据关联存储到医疗数据库中。

具体地,在获取到第二体检数据后,提取第二体检数据中已确诊患者的患者标识,再从确诊数据库中提取患者标识对应的确诊数据。将同一个患者标识对应的确诊数据和第二体检数据进行关联,并存储到医疗数据库中。

在本技术方案中,数据服务器将同一个患者标识的确诊数据和第二体检数据进行关联存储,具体可以分别提取同一个患者标识的确诊数据和第二体检数据中的特征数据,建立特征数据的对应关系表,通过特征数据的对应关系表,将同一个患者标识对应的确诊数据和第二体检数据关联,并将关联后的确诊数据和第二体检数据存储到医疗数据库中;也可以通过患者标识将同一个患者标识对应的确诊数据和第二体检数据进行关联,将患者标识、确诊数据和第二体检数据对应存储在医疗数据库中。

(3)关联数据提取模块3,用于从医疗数据库中提取第二体检数据和第二体检数据对应的确诊数据。

(4)神经网络训练模块4,用于根据提取到的第二体检数据和第二体检数据对应的确诊数据,训练得到深度学习神经网络。

具体地,从医疗数据库中获取多个已确诊患者的患者标识对应的第二体检数据和第二体检数据对应的确诊数据,以获取到的第二体检数据和第二体检数据对应的确诊数据作为训练样本,将第二体检数据作为深度学习神经网络的输入,并将第二体检数据对应的已确诊患者的确诊数据作为深度学习神经网络的输出,通过训练得到深度学习神经网络。

在本技术方案中,医疗数据库中存储着海量已确诊患者的确诊数据和第二体检数据,并且将同一患者标识对应的确诊数据和体检数据关联存储,

为训练深度学习神经网络提供了大数据支撑。通过医疗数据库中海量已确诊患者的数据对深度学习神经网络进行训练，提高了通过神经网络生成确诊结果的准确性。

(5) 第一数据获取模块 5，用于获取覆盖待确诊患者身体各部分的第一体检数据。

具体地，对待确诊患者身体各部位进行检查，通过检查，生成患者的第一体检数据，具体可以对待确诊患者进行覆盖身体各部分的扫描，来获取待确诊患者的第一体检数据。

(6) 确诊结果获得模块 6，用于利用深度学习神经网络对第一体检数据进行运算，得到第一体检数据对应的确诊结果；所述深度学习神经网络是根据覆盖已确诊患者身体各部分的第二体检数据和第二体检数据对应的确诊数据训练得到的。

将获取到的第一体检数据输入训练得到的深度学习神经网络中，利用神经网络对第一体检数据进行运算，得到第一体检数据对应的确诊结果，确诊结果可以是疾病名称，也可以是疾病名称对应的编码。

(7) 异常指标确定模块 7，用于根据确诊结果确定异常体检指标。

(8) 异常数值提取模块 8，用于在第一体检数据中提取异常体检指标对应的数值。

(9) 确诊报告生成模块 9，用于根据异常体检指标对应的数值和确诊结果生成确诊报告。

具体地，体检指标是在体检数据中能够反映人身体健康状况的检测项目，如心率、血压和尿酸等，每个体检指标对应的数值都有一个正常范围，根据体检指标的数值是否在正常范围内可以判断人身体的健康状况。若体检指标的数值超出该体检指标对应的正常范围，则该体检指标为异常体检指标。

在生成确诊结果后,根据确诊结果与异常体检指标的对应关系确定异常体检指标的体检指标标识,根据确定的体检指标标识在第一体检指标中查找异常体检指标的数值并提取,根据提取的异常体检指标的数值和确诊结果,生成相应的待确诊患者的确诊报告。其中,确诊结果与异常体检指标的对应关系可以通过数据服务器以医疗数据库中存储的部分或全部数据作为样本,进行分析获得的,也可以是预先设置的确诊结果与异常体检指标的对应关系表。

在本技术方案中,生成确诊结果后,根据确诊结果提取第一体检数据中的异常体检指标的数值,并根据确诊结果和异常体检指标的数值生成确诊报告,确诊报告可以准确、详细地反映待确诊患者的健康状况。

如图 5-4 所示,在本技术方案中,确诊结果获得模块 6 包括:体检数值提取模块 6-1、体检数值编码模块 6-2、编码数据运算模块 6-3 和疾病名称确定模块 6-4。

(1) 体检数值提取模块 6-1,用于提取第一体检数据中各体检指标的数值。

(2) 体检数值编码模块 6-2,用于分别对各体检指标的数值进行编码,生成各体检指标对应的编码数据,编码数据包括指标标识和指标数值。

(3) 编码数据运算模块 6-3,用于将编码数据输入深度学习神经网络,使深度学习神经网络将编码数据输入与编码数据中指标标识对应的节点进行运算,得到运算结果。

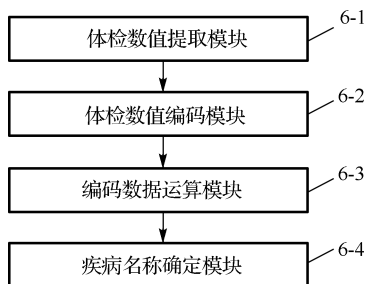


图 5-4 确诊结果获取模块 6 的结构图

(4) 疾病名称确定模块 6-4，用于根据运算结果确定与第一体检数据对应的疾病名称。

具体地，体检数据提取模块提取第一体检数据中各体检指标的数值，查找与体检指标名称匹配的指标标识。指标标识用于区别不同的体检指标，具体可以是字符和数字中的至少一种。将指标标识添加到体检指标的数值中，形成编码数据。编码数据包括指标标识和指标数值，具体可以是二进制数值。数据服务器将编码数据输入深度学习神经网络中，神经网络读取编码数据中的指标标识，并查找指标标识对应的节点，提取编码数据中的指标数值，将指标数值输入指标标识对应的节点。深度学习神经网络根据输入的指标数值运算，得到运算结果，运算结果可以是字符或数值中的至少一种，查找与运算结果对应的疾病名称，并将查找到的疾病名称输出，作为待确诊患者的确诊结果。

在本技术方案中，通过各体检指标进行编码生成编码数据，根据编码数据中指标标识将编码数据中的指标数值输入相应的深度学习神经网络节点，通过对体检指标进行编码保证了神经网络节点的输入准确率，从而使运算结果更加准确，进而辅助医生更加快速、准确、合理地做出诊断。

如图 5-5 所示，确诊结果获得模块 6 还包括：体检数值提取模块 6-5、体检数值处理模块 6-6 和标准化值运算模块 6-7。




图 5-5 确诊结果获得模块 6 的结构图

(5) 体检数值提取模块 6-5, 用于提取第一体检数据中各体检指标的数值。

(6) 体检数值处理模块 6-6, 用于对各体检指标的数值进行标准化处理, 得到各体检指标的标准化值。

具体地, 提取第一体检数据中各体检指标的数值, 通过标准化处理将该数值根据各体检指标的映射关系映射到特定区间中, 其中, 特定的区间具体可以是 $[-1,0]$ 、 $[0,1]$ 或 $[-1,1]$ 。

例如, 利用体检指标的数值减去该体检指标的最小值得到差 x_1 , 再利用该体检指标的最大值减去最小值得到差 x_2 , 利用 x_1 除以 x_2 得到体检指标的数值在区间 $[0,1]$ 中的标准化值。

数据服务器还用于提取第一体检数据中各体检指标对应的值, 查找提取到的值不是数值的体检指标, 将查找到的体检指标的值转换成数值, 以各体检指标对应的数值为标准化值。例如, 体检指标“尿葡萄糖”对应的值是“阴性”, 该体检指标对应的值不是数值, 则将“阴性”转换为“1”, 将“阳性”转换为“0”。

若第一体检指标中各体检指标对应的数值格式不同, 则数据服务器对各体检指标对应的数值格式进行调整, 使其数值格式一致, 以格式调整后的数值作为各体检指标对应的标准化值。

(7) 标准化值运算模块 6-7, 用于将各体检指标的标准化值输入深度学习神经网络, 神经网络将各体检指标的标准化值输入相应的节点, 并根据神经网络中节点之间的权重值对各体检指标的标准化值进行运算, 得到第一体检数据对应的确诊结果。

具体地, 在对各体检指标的数值进行标准化处理后, 得到各体检指标的标准化值, 将其输入深度学习神经网络, 神经网络将各体检指标的标准化值输入各体检指标对应的节点, 然后根据各节点之间的权重值对输入的各体检指标的标准化值进行加权运算, 通过多次加权运算得到最终的运算结果。根

据运算结果查找对应的疾病名称,并将疾病名称作为第一体检数据对应的确诊结果。

本技术方案通过对标准化值进行计算,节省了确诊结果的生成过程中的运算资源,提高了运算效率,同时也提高了确诊结果的准确性和生成效率。

5.2 基于双深度学习的数据处理方法和疾病诊断装置

本节研究了一种基于双深度学习的数据处理方法和疾病诊断装置,该方法包括:根据预先训练好的第一深度学习神经网络的输入变量获取对应的第一输入数据,将第一输入数据输入第一深度学习神经网络中,通过计算得到第一输出结果;当第一输出结果中包含标识有疾病的标签时,根据预先训练好的第二深度学习神经网络的输入变量获取对应的第二输入数据,将第二输入数据输入第二深度学习神经网络中,通过计算得到第二输出结果;其中,第一深度学习神经网络的输入变量集合是所述第二深度学习神经网络的输入变量集合的子集。此外,本节还提供了一种基于双深度学习的疾病诊断装置。

5.2.1 研究现状

传统技术中,采用深度学习神经网络对患者进行诊断时^[42-53],需要对深度学习神经网络的输入变量集合进行采集,将所有的输入变量输入对应的深度学习神经网络中,通过计算得到输出数据,才能够诊断出具体的疾病类型,而输入变量中很多数据都是非必需项,采集过多的输入变量(如体重、血压、血液检查结果等)不仅给患者带来了负担,而且给紧缺的医疗资源带来更大的压力和浪费。

本节针对技术现状中存在的问题,提供一种能够有效避免需要采集过多的数据才能诊断出疾病类型的基于双深度学习的数据处理方法和疾病诊断装置,通过预先训练好的第一深度学习神经网络计算得到第一输出结果,根据第一输出结果中是否包含标识有疾病的标签(如果没有包含疾病,则无须通过第二深度学习神经网络进行进一步的判断;如果包含疾病,则再根据预先训练好的第二深度学习神经网络通过计算,得到第二输出结果),得知是否患病,再根据第二深度学习神经网络得知具体患病的类型。其中,第一深度学习神经网络的输入变量集合是第二深度学习神经网络的输入变量集合的子集,可以有效避免需要采集过多的数据才能诊断出具体疾病类型的问题,减轻患者的负担,给紧缺的医疗资源减轻压力。

5.2.2 基于双深度学习的数据处理方法

如图 5-6 所示,在本技术方案中,提供了一种基于双深度学习的数据处理方法,具体包括以下步骤:

(1)步骤 S1:从第二深度学习神经网络的输入变量集合中至少选取一个变量子集,将选取的变量子集作为该变量子集对应的第一深度学习神经网络的输入变量集合,初始化该变量子集对应的第一深度学习神经网络。

第二深度学习神经网络的输入变量集合是由第一深度学习神经网络的输入变量集合中的元素组成的,即第一深度学习神经网络的输入变量集合是第二深度学习神经网络的输入变量集合的子集。将第二深度学习神经网络的输入变量集合中的元素变量组合成多个变量子集,其中,变量子集方式包括但不限于单个输入变量的变量子集、两个输入变量的变量子集、三个输入变量的变量子集等,根据多个变量子集初始化每个变量子集对应的第一深度学习神经网络。例如,第二深度学习神经网络的输入变量集合为体重、血压、血液检查结果、尿液检查结果。

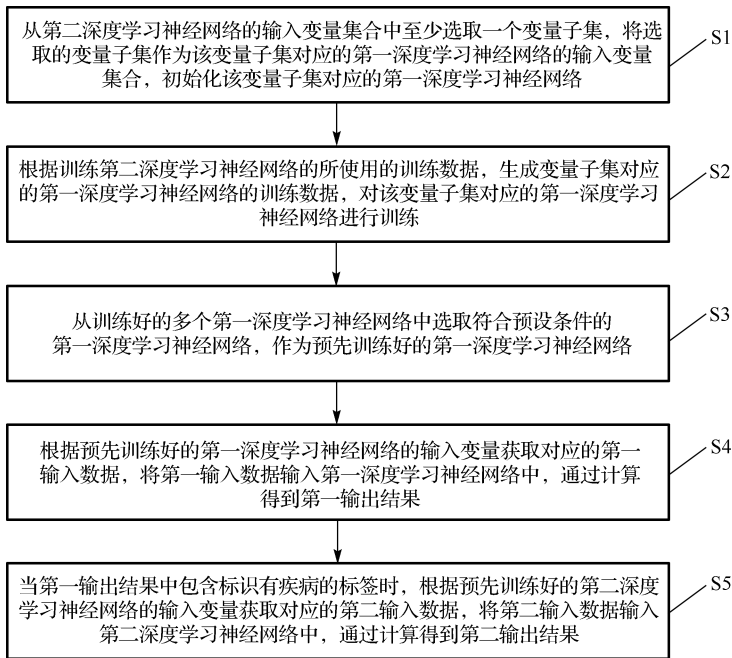


图 5-6 基于双深度学习的数据处理方法的流程图

则输入变量集合的多个子集为：

变量子集 1：体重、血压、血液检查结果、尿液检查结果；

变量子集 2：血压、血液检查结果、尿液检查结果；

变量子集 3：体重、血液检查结果、尿液检查结果；

变量子集 4：体重、血压、尿液检查结果；

变量子集 5：体重、血压、血液检查结果；

变量子集 6：体重、尿液检查结果；

变量子集 7：体重、血压；

变量子集 8：体重、血液检查结果；

变量子集 9：血压、血液检查结果；

变量子集 10：血压、尿液检查结果；

变量子集 11：血液检查结果、尿液检查结果；

变量子集 12: 体重;

变量子集 13: 血压;

变量子集 14: 血液检查结果;

变量子集 15: 尿液检查结果。

(2) 步骤 S2: 根据训练第二深度学习神经网络的所使用的训练数据, 生成变量子集对应的第一深度学习神经网络的训练数据, 对该变量子集对应的第一深度学习神经网络进行训练。

由于需要使用输入数据和输出数据对第二深度学习神经网络进行训练, 同样地, 对该变量子集对应的第一深度学习神经网络进行训练才能进行预测。

(3) 步骤 S3: 从训练好的多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络, 作为预先训练好的第一深度学习神经网络。

其中, 优选地, 可包括但不限于预测准确率较大的第一深度学习神经网络。

(4) 步骤 S4: 根据预先训练好的第一深度学习神经网络的输入变量获取对应的第一输入数据, 将第一输入数据输入第一深度学习神经网络中, 通过计算得到第一输出结果。

其中, 第一输入数据为与第一深度学习神经网络的输入变量对应的各种输入数据, 如血压、体重、血液检查结果、尿液检查结果等, 第一输出结果可根据这些数据预测患者是否患有糖尿病等。

(5) 步骤 S5: 当第一输出结果中包含标识有疾病的标签时, 根据预先训练好的第二深度学习神经网络的输入变量获取对应的第二输入数据, 将第二输入数据输入第二深度学习神经网络中, 通过计算得到第二输出结果。

例如, 第一深度学习神经网络的输入变量为体重和尿液检查结果, 获取

输入数据，通过第一深度学习神经网络计算得到的第一输出结果为患有糖尿病，则根据第二深度学习神经网络的输入变量(体重、尿液检查结果、血压、血液检查结果)获取输入数据，通过第二深度学习神经网络计算可预测患有糖尿病的类型。

1. 步骤 S2

如图 5-7 所示，在本技术方案中，根据所述第二深度学习神经网络所使用的训练数据，生成变量子集对应的第一深度学习神经网络的训练数据，对该变量子集对应的第一深度学习神经网络进行训练，步骤 S2 包括：

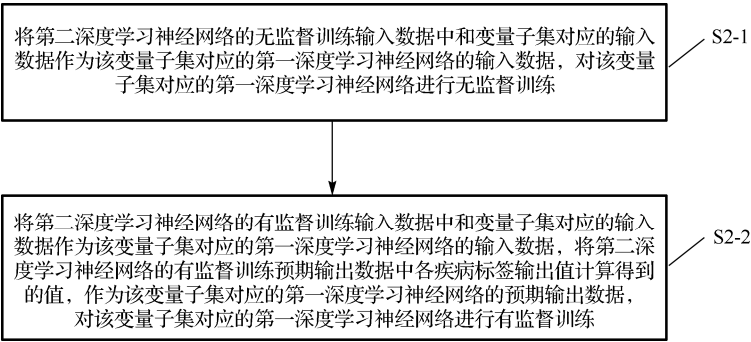


图 5-7 步骤 S2 的流程图

(1) 步骤 S2-1：将第二深度学习神经网络的无监督训练输入数据中和变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据，对该变量子集对应的第一深度学习神经网络进行无监督训练。

无监督训练包含很多输入数据，是为了学习输入数据的特征。例如，第二深度学习神经网络的无监督训练使用的输入数据为：

- 训练输入数据 1：体重 1、血压 1、血液检查结果 1、尿液检查结果 1；
- 训练输入数据 2：体重 2、血压 2、血液检查结果 2、尿液检查结果 2；
- 训练输入数据 3：体重 3、血压 3、血液检查结果 3、尿液检查结果 3。

若变量子集为体重、尿液检查结果，则该变量子集对应的第一深度学习神经网络的无监督训练数据为：

训练输入数据 1：体重 1、尿液检查结果 1；

训练输入数据 2：体重 2、尿液检查结果 2；

训练输入数据 3：体重 3、尿液检查结果 3。

(2) 步骤 S2-2：将第二深度学习神经网络的有监督训练输入数据中和变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据，将第二深度学习神经网络的有监督训练预期输出数据中各疾病标签输出值计算得到的值，作为该变量子集对应的第一深度学习神经网络的预期输出数据，对该变量子集对应的第一深度学习神经网络进行有监督训练。

有监督训练的训练数据是指在众多训练数据中既有输入数据，又有预期输出数据。其中所述“计算得到的值”的“计算”可以是求并，求并是指只要疾病标签输出的值有一个为 1，则总输出值为 1(1 代表患有疾病)，如果疾病标签输出的值全为 0，则总输出值为 0(0 代表未患病)。例如，第二深度学习神经网络的有监督训练使用的输入数据为：

训练输入数据 1：体重 1、血压 1、血液检查结果 1、尿液检查结果 1；

有监督训练预期输出数据 1：1 型糖尿病为 0、2 型糖尿病为 1、妊娠糖尿病为 0、特殊类型的糖尿病为 0；

训练输入数据 2：体重 2、血压 2、血液检查结果 2、尿液检查结果 2；

有监督训练预期输出数据 2：1 型糖尿病为 1、2 型糖尿病为 1、妊娠糖尿病为 0、特殊类型的糖尿病为 1；

训练输入数据 3：体重 3、血压 3、血液检查结果 3、尿液检查结果 3；

有监督训练预期输出数据 3：1 型糖尿病为 0、2 型糖尿病为 0、妊娠糖尿病为 0、特殊类型的糖尿病为 0；

.....

若变量子集为体重、尿液检查结果，则该变量子集对应的第一深度学习神经网络的有监督训练数据为：

- 训练输入数据 1：体重 1、尿液检查结果 1；
- 有监督训练预期输出数据 1： $0 \cup 1 \cup 0 \cup 0 = 1$ ；
- 训练输入数据 2：体重 2、尿液检查结果 2；
- 有监督训练预期输出数据 2： $1 \cup 1 \cup 0 \cup 1 = 1$ ；
- 训练输入数据 3：体重 3、尿液检查结果 3；
- 有监督训练预期输出数据 3： $0 \cup 0 \cup 0 \cup 0 = 0$ ；
-

2. 步骤 S3

如图 5-8 所示，在本技术方案中，从训练好的多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络作为预先训练好的第一深度学习神经网络，步骤 S3 包括：

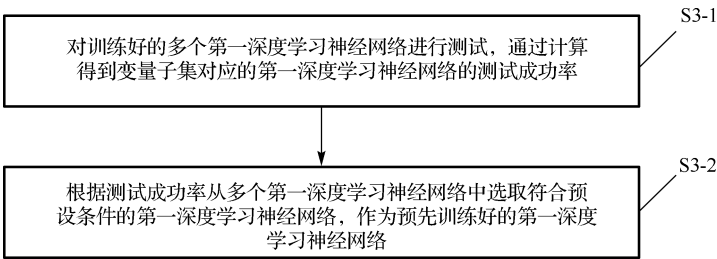


图 5-8 步骤 S3 的流程图

(1) 步骤 S3-1：对训练好的多个第一深度学习神经网络进行测试，通过计算得到变量子集对应的第一深度学习神经网络的测试成功率。

由于需要根据训练好的第一深度学习神经网络进行预测，即需要对已经进行无监督训练和有监督训练计算得到的每个变量子集对应的第一深度学习神经网络进行测试。测试的目的是通过计算得到变量子集对应的第一深

度学习神经网络的测试成功率。其中，测试成功率越大，说明预测的准确性越高。

(2) 步骤 S3-2: 根据测试成功率从多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络，作为预先训练好的第一深度学习神经网络。

在通过计算得到每个变量子集对应的第一深度学习神经网络的测试成功率后，在多个第一深度学习神经网络中选取测试成功率最大的第一深度学习神经网络，作为预先训练好的第一深度学习神经网络。测试成功率越大，说明对应的第一深度学习神经网络的预测准确率越高。其中，在选取测试成功率最大的第一深度学习神经网络时，会遇到测试成功率相同的情况，此时，可依据患者的其他条件进行选取。

在本技术方案中，对训练好的多个第一深度学习神经网络进行测试，通过计算得到变量子集对应的第一深度学习神经网络的测试成功率，其包括：将第二深度学习神经网络的测试输入数据中与变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据，将第二深度学习神经网络的测试预期输出数据中各疾病标签输出值计算得到的值，作为该变量子集对应的第一深度学习神经网络的预期输出数据，对该变量子集对应的第一深度学习神经网络进行测试，通过计算得到变量子集对应的第一深度学习神经网络的测试成功率。

在本技术方案中，变量子集对应的第一深度学习神经网络的测试成功率为该变量子集对应的第一深度学习神经网络的测试实际输出和所述预期输出数据一致的测试次数与总测试次数的比值。

第二深度学习神经网络经过无监督训练和有监督训练，得到训练后的第二深度学习神经网络，为了获得预测准确率更高的第二深度学习神经网络，需要对第二深度学习神经网络进行测试，将对第二深度学习神经网络进行测

试时所使用的测试输入数据中与变量子集对应的输入数据,作为该变量子集对应的第一深度学习神经网络的输入数据,将对第二深度学习神经网络测试的预期输出数据中各疾病标签输出值求“并”得到的值,作为该变量子集对应的第一深度学习神经网络的预期输出数据。其中,测试预期输出数据是指第二深度学习神经网络在进行测试时预期输出的数据。再对该变量子集对应的第一深度学习神经网络进行测试,得到对应的测试成功率。同样地,变量子集对应的第一深度学习神经网络的测试成功率越大,对应的第一深度学习神经网络的预测准确率越高。

测试成功率,具体是根据变量子集对应的第一深度学习神经网络的测试实际输出和所述预期输出数据一致的测试次数与总测试次数的比值得到的。其中,测试实际输出是指将变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据,计算得到对应的测试实际输出数据。

例如,第二深度学习神经网络的测试数据为:

测试输入数据 1: 体重 1'、血压 1'、血液检查结果 1'、尿液检查结果 1';

测试预期输出数据 1: 1 型糖尿病为 1、2 型糖尿病为 1、妊娠糖尿病为 0、特殊类型的糖尿病为 0;

输入数据 2: 体重 2'、血压 2'、血液检查结果 2'、尿液检查结果 2';

测试预期输出数据 2: 1 型糖尿病为 0、2 型糖尿病为 1、妊娠糖尿病为 1、特殊类型的糖尿病为 0;

.....

若变量子集为体重、尿液检查结果,则该变量子集对应的第一深度学习神经网络的测试数据为:

测试输入数据 1: 体重 1'、尿液检查结果 1';

测试预期输出数据 1: $1 \cup 1 \cup 0 \cup 0 = 1$ (对第二深度学习神经网络的测试的预期输出数据进行求并计算);

测试实际输出数据 1: 1。

此次测试实际输出与同次测试的测试预期输出一致。

输入数据 2: 体重 2'、尿液检查结果 2';

测试预期输出数据 2: $0 \cup 1 \cup 1 \cup 0 = 1$;

测试实际输出数据 2: 0。

此次测试实际输出与同次测试的测试预期输出不一致。

.....

若测试预期输出数据与测试实际输出数据一致的次数为 90, 总次数为 100, 则该变量子集对应的第一深度学习神经网络的测试成功率为 90%。

根据测试成功率, 从多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络作为所述预先训练好的第一深度学习神经网络, 包括:

从多个变量子集对应的多个第一深度学习神经网络中选取测试成功率最高的第一深度学习神经网络作为预先训练好的第一深度学习神经网络;

从多个变量子集对应的多个第一深度学习神经网络中选取测试成功率大于测试成功率预设值, 且变量子集中的变量数量最少的第一深度学习神经网络作为预先训练好的第一深度学习神经网络;

从多个变量子集对应的多个第一深度学习神经网络中选取测试成功率大于测试成功率预设值, 且变量子集中的变量数量小于变量数量预设值, 且变量子集中的变量对应的数据采集成本最低的第一深度学习神经网络作为预先训练好的第一深度学习神经网络。

其中, 预设条件包括测试成功率最高、变量子集中的变量数量最少、变量子集中的变量对应的数据采集成本最低中的至少一个。

在另一个技术方案中, 对多个第一深度学习神经网络进行测试。通过计算得到每个第一深度学习神经网络的测试成功率。此时, 如果出现测试成功

率相同的多个变量子集对应的多个第一深度学习神经网络，则在这些神经网络中，选取变量子集中数量最少且变量子集对应的数据采集成本最低的第一深度学习神经网络作为预先训练好的第一深度学习神经网络。例如，医学检查及采集的成本为：体重为免费、血压为免费、血液检查结果为 200 元、尿液检查结果为 50 元。

变量子集 1：体重、血压、血液检查结果、尿液检查结果；

对应的第一深度学习神经网络的成功率为 100%；

医学检查及采集的成本为 $0+0+200+50 = 250$ 。

变量子集 2：血压、血液检查结果、尿液检查结果；

对应的第一深度学习神经网络的成功率为 96%；

医学检查及采集的成本为 $0+200+50 = 250$ 。

变量子集 3：体重、血液检查结果、尿液检查结果；

对应的第一深度学习神经网络的成功率为 99%；

医学检查及采集的成本为 $0+200+50 = 250$ 。

变量子集 4：体重、血压、尿液检查结果；

对应的第一深度学习神经网络的成功率为 100%；

医学检查及采集的成本为 $0+0+50 = 50$ 。

变量子集 5：体重、血压、血液检查结果；

对应的第一深度学习神经网络的成功率为 98%；

医学检查及采集的成本为 $0+0+200 = 200$ 。

变量子集 6：体重、尿液检查结果；

对应的第一深度学习神经网络的成功率为 90%；

医学检查及采集的成本为 $0+50 = 50$ 。

变量子集 7：体重、血压；

对应的第一深度学习神经网络的成功率为 10%；

医学检查及采集的成本为 $0+0=0$ 。

变量子集 8：体重、血液检查结果；

对应的第一深度学习神经网络的成功率为 80%；

医学检查及采集的成本为 $0+200=200$ 。

变量子集 9：血压、血液检查结果；

对应的第一深度学习神经网络的成功率为 70%；

医学检查及采集的成本为 $0+200=200$ 。

变量子集 10：血压、尿液检查结果；

对应的第一深度学习神经网络的成功率为 80%；

医学检查及采集的成本为 $0+50=50$ 。

变量子集 11：血液检查结果、尿液检查结果；

对应的第一深度学习神经网络的成功率为 90%；

医学检查及采集的成本为 $200+50=250$ 。

变量子集 12：体重；

对应的第一深度学习神经网络的成功率为 2%；

医学检查及采集的成本为 0。

变量子集 13：血压；

对应的第一深度学习神经网络的成功率为 1%；

医学检查及采集的成本为 0。

变量子集 14：血液检查结果；

对应的第一深度学习神经网络的成功率为 20%；

医学检查及采集的成本为 200。

变量子集 15：尿液检查结果；

对应的第一深度学习神经网络的成功率为 70%；

医学检查及采集的成本为 50。

从多个第一深度学习神经网络中选取测试成功率最大的变量子集对应的第一深度学习神经网络有：变量子集 1 对应的第一深度学习神经网络和变量子集 4 对应的第一深度学习神经网络，这两个变量子集对应的第一深度学习神经网络的测试成功率都为 100%，再根据变量子集中数量最少而且变量子集对应的数据采集成本最低的变量子集 4 对应的第一深度学习神经网络作为预先训练好的第一深度学习神经网络。

还可以获取用户关注点。当用户关注点为准确率优先时，从所有变量子集对应的第一深度学习神经网络中，选取测试成功率最大，且变量子集中各输入变量的数据所需医学检查及采集的成本之和最低，且输入变量数最少的一种变量子集对应的第一深度学习神经网络，作为优选第一深度学习神经网络返回给用户；当用户关注点为成本优先时，选取测试成功率大于预设成功率阈值，且变量子集中各输入变量的数据所需医学检查及采集的成本之和最小，且输入变量数最少的一种变量子集对应的第一深度学习神经网络，作为优选第一深度学习神经网络返回给用户。

如果用户关注点为准确率优先，则测试成功率最大的变量子集对应的第一深度学习神经网络包括变量子集 1 对应的第一深度学习神经网络、变量子集 4 对应的第一深度学习神经网络，成功率均为 100%，在这两种变量子集对应的第一深度学习神经网络中，变量子集 4 对应的第一深度学习神经网络的成本 50 为最小，所以选择变量子集 4 对应的第一深度学习神经网络作为优选第一深度学习神经网络返回给用户。

如果用户关注点为成本优先，且预设成功率阈值为 90%，则测试成功率大于 90%的变量子集对应的第一深度学习包括变量子集 1、2、3、4、5、6、11 对应的第一深度学习神经网络，在这 7 种变量子集对应的第一深度学习神经网络中，变量子集 4、6 对应的第一深度学习的成本 50 为最小，其中 6 对应的第一深度学习神经网络的输入变量数最少，所以选择变量子集 6 对应的

第一深度学习神经网络作为优选第一深度学习神经网络返回给用户。

在一个具体技术方案中，将第一深度学习神经网络作为用于初诊的深度学习神经网络，将第二深度学习神经网络作为用于确诊的深度学习神经网络。通过用于初诊的深度学习神经网络进行初步诊断，用于初诊的深度学习神经网络只需要少量的患者数据项，进行少量的检查，如果用于初诊的深度学习神经网络诊断的结果是病人没有该科的疾病，则不需要再使用该科用于确诊的深度学习神经网络进行检测。如果用于初诊的深度学习神经网络诊断的结果是病人有该科的疾病，再通过该科用于确诊的深度学习神经网络进行进一步诊断，具体得了该科的什么类型的疾病，而用于初诊的深度学习神经网络的输入变量只占用确诊的深度学习神经网络输入变量的一部分，降低没有患该科疾病的病人的检查成本和额外检查给身体造成的伤害。

5.2.3 基于双深度学习的疾病诊断装置

如图 5-9 所示，在本技术方案中，提供了一种基于双深度学习的疾病诊断装置，该装置包括：

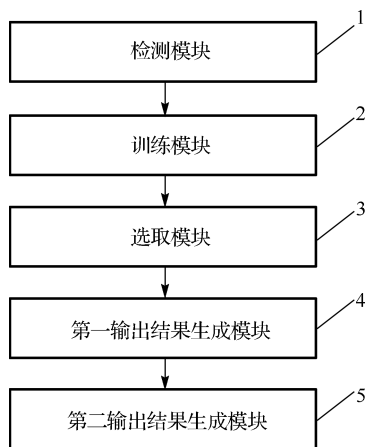


图 5-9 基于双深度学习的疾病诊断装置的结构图

(1)检测模块 1,用于从第二深度学习神经网络的输入变量集合中选取至少一个变量子集,将选取的变量子集作为该变量子集对应的第一深度学习神经网络的输入变量集合,初始化该变量子集对应的第一深度学习神经网络。

(2)训练模块 2,用于根据训练第二深度学习神经网络所使用的训练数据生成变量子集对应的第一深度学习神经网络的训练数据,对该变量子集对应的第一深度学习神经网络进行训练。

(3)选取模块 3,用于在训练好的多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络,作为预先训练好的第一深度学习神经网络。

(4)第一输出结果生成模块 4,用于根据预先训练好的第一深度学习神经网络的输入变量获取对应的第一输入数据,将第一输入数据输入第一深度学习神经网络,通过计算得到第一输出结果。

(5)第二输出结果生成模块 5,用于当第一输出结果中包含标识有疾病的标签时,根据预先训练好的第二深度学习神经网络的输入变量获取对应的第二输入数据,将第二输入数据输入所述第二深度学习神经网络,通过计算得到第二输出结果;其中,第一深度学习神经网络的输入变量集合是第二深度学习神经网络的输入变量集合的子集。

在本技术方案中,训练模块包括无监督训练单元和有监督训练单元,其中:

无监督训练单元,用于将第二深度学习神经网络的无监督训练输入数据中和变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据,对该变量子集对应的第一深度学习神经网络进行无监督训练。

有监督训练单元,用于将第二深度学习神经网络的有监督训练输入数据中和变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络

络的输入数据,将第二深度学习神经网络的有监督训练预期输出数据中各疾病标签输出值计算得到的值,作为该变量子集对应的第一深度学习神经网络的预期输出数据,对该变量子集对应的第一深度学习神经网络进行有监督训练。

在本技术方案中,选取模块包括测试单元和第一深度学习神经网络确定单元,其中:

测试单元,用于对训练好的多个第一深度学习神经网络进行测试,通过计算得到变量子集对应的第一深度学习神经网络的测试成功率。

第一深度学习神经网络确定单元,用于根据测试成功率,从多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络作为预先训练好的第一深度学习神经网络。

测试单元还用于将第二深度学习神经网络的测试输入数据中与变量子集对应的输入数据作为该变量子集对应的第一深度学习神经网络的输入数据,将第二深度学习神经网络的测试预期输出数据中各疾病标签输出值计算得到的值,作为该变量子集对应的第一深度学习神经网络的预期输出数据,对该变量子集对应的第一深度学习神经网络进行测试,通过计算得到变量子集对应的第一深度学习神经网络的测试成功率。

在一个技术方案中,变量子集对应的第一深度学习神经网络的测试成功率为该变量子集对应的第一深度学习神经网络的测试实际输出和预期输出数据一致的测试次数与总测试次数的比值。

在另一个技术方案中,第一深度学习神经网络确定单元还用于从多个第一深度学习神经网络中选取符合预设条件的第一深度学习神经网络作为预先训练好的第一深度学习神经网络。其中,预设条件包括测试成功率最大、变量子集中的变量数量最少、变量子集中的变量对应的数据采集成本最低中的至少一个。

第 6 章 深度学习的大数据智能预测应用

本章给出了两种深度学习的大数据智能预测应用：基于大数据与深度学习的气象预报方法和系统、基于大数据与深度学习的用户数据处理方法和系统。

6.1 基于大数据与深度学习的气象预报方法和系统

本节研究了一种气象预报方法和系统。该方法包括：获取预报区域的最近设定时长内的气象分析场序列；将所述最近气象分析场序列输入所述预报区域的深度学习神经网络进行学习，得到所述预报区域的深度学习神经网络的输出；将输出作为预报区域的自当前时刻开始的预报时长内的预报场序列。该系统包括：分析场获取模块，用于获取预报区域的最近设定时长内的气象分析场序列；预报模块，用于将所述最近气象分析场序列输入所述预报区域的深度学习神经网络进行深度学习，得到所述预报区域的深度学习的输出；将所述输出作为预报区域的自当前时刻开始的预报时长内的预报场序列。上述方法和系统，使气象预报更加准确。

6.1.1 研究现状

天气变化与人们的生产活动、社会活动、军事活动及日常生活都有着十分密切的关系。一直以来，人们总是想方设法去预测未来的天气变化，利用

有利的天气，同时提前预防不利天气带来的气象灾害^[54-61]。

传统技术中，人们预测天气采用数值预测的方法。数值预测的原理为：通过天气图或卫星云图获取气象图像，并在一定的初值和边值条件下，利用大型计算机进行数值计算，求解描写天气演变过程的流体力学和热力学的方程组，预测未来一定时段内的大气运动状态和天气现象。上述的数值预测方法是基于数学模型进行模式推导的，误差较大。

基于此，有必要提出一种预测较为准确的气象预报方法。采用深度学习神经网络对最近预报时长内的气象分析场序列进行学习，得到从当前时间开始的预报时长内的预报场，深度学习神经网络的预测精度非常高(这已经在很多应用中得到了印证，如图像识别，而气象分析场序列与图像数据没有本质上的区别)，例如，将气象分析场中每个点作为一个像素点，用该像素点的 RGB 表示气象分析场中该点的属性值，则每个气象分析场都可以用一个图像来表示。而气象分析场序列由多个气象分析场有序组成，等同于多个图像有序组成一个更大的图像。所以深度学习神经网络可以高精度地预测气象，使预测结果更加准确，这种预测结果可以与模式预报的结果一起作为预报员预报的参考依据，使预报员能做出更为准确的天气预报。

6.1.2 基于大数据与深度学习的气象预报方法

如图 6-1 所示，为一种技术方案的气象预报方法流程图。该方法包括以下步骤：

(1) 步骤 S1：对预报区域的深度学习神经网络进行训练。

深度学习神经网络的特点是，经过大量有效数据的训练后，其预测的准确性会更高。在执行预测步骤之前，需要保证预报区域的深度学习神经网络具有相当程度的预测准确率，否则应该首先执行大量的训练过程，再将深度学习神经网络用于气象预报。

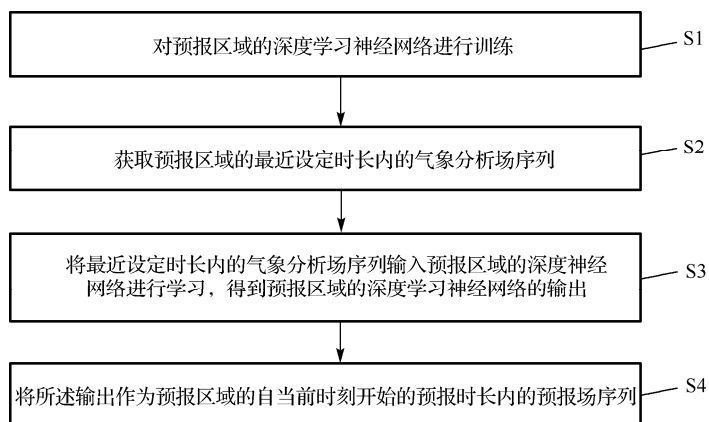


图 6-1 气象预报方法流程图

(2) 步骤 S2：获取预报区域的最近设定时长内的气象分析场序列。

预报区域是指准备进行气象预报的区域，范围可根据需求确定。例如，在中国可按照省、市等行政区域进行确定。最近设定时长内是指以当前时间为分界点，在当前时间之前的最近的一个设定时长的时间段内。气象分析场是指用实况资料做的分析数据，应是真实的、确定的。气象分析场在气象预报领域的含义是所属领域的技术人员所熟知的。

气象分析场序列由多个时间点的气象分析场有序组成。例如，设定时长是 60 分钟，且假定气象分析场的时间分辨率是 1 分钟，那么 60 分钟内会有 60 个气象分析场，这 60 个气象分析场按照时间先后顺序排列，就组成了一个时长为 60 分钟的气象分析场序列。例如，预报区域为深圳市，预报时长为 12 小时，就是从当前时刻开始的将来的 12 个小时。

如图 6-2 所示，例如，当前时刻是 4 月 11 日 12 点 00 分，预报区域的最近的设定时长内的气象分析场序列就是 4 月 11 日 11 点 00 分至 4 月 12 日 00 点 00 分的气象分析场序列。

(3) 步骤 S3：将最近设定时长内的气象分析场序列输入预报区域的深度学习神经网络进行学习，得到预报区域的深度学习神经网络的输出。




图 6-2 各时间点和时间段在时间轴上的相对位置示意图

深度学习神经网络特指预报区域的神经网络。其以该预报区域的气象分析场序列为输入，根据输入得到神经网络的输出。

(4) 步骤 S4：将所述输出作为预报区域的自当前时刻开始的预报时长内的预报场序列。

例如，预报时长为 12 小时，预报时长内则为 4 月 11 日 12 点 00 分到 4 月 12 日 00 点 00 分。

1. 步骤 S1

如图 6-3 所示，步骤 S1 包括：

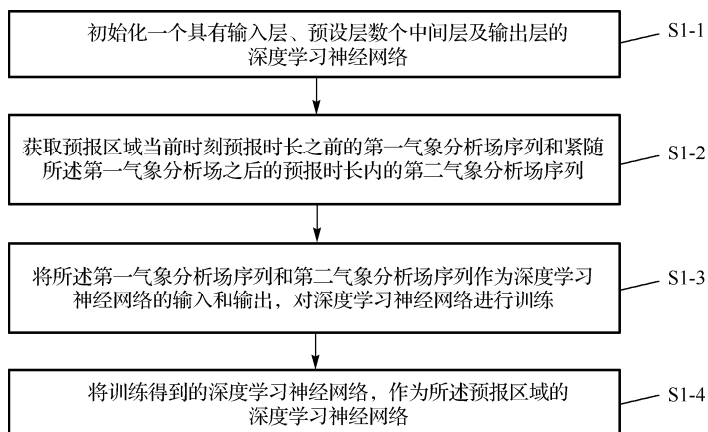


图 6-3 步骤 S1 的流程图

(1) 步骤 S1-1：初始化一个具有输入层、预设层数个中间层及输出层的深度学习神经网络。

其中,预设层数小于设定时长内的气象分析场序列中的气象分析场的数量。

(2) 步骤 S1-2: 获取预报区域当前时刻预报时长之前的第一气象分析场序列和紧随所述第一气象分析场之后的预报时长内的第二气象分析场序列。

其中,第一气象分析场序列为任意符合预设条件的设定时长内的气象分析场序列。预设条件为无条件或季节条件。季节条件是指,当前预报时间所在的季节与输入的气象分析场序列数据应该在季节上一致,如100天之内。

如图6-4所示,当前时刻是4月11日12点00分,预报时长为12小时,则12小时之前是4月11日00点00分之前。那么在这个例子中,当前时刻预报时长之前,就是4月11日00点00分之前。在4月11日00点00分之前,取任意设定时长内(如4月9日23点00分到4月10日00点00分)的气象分析场序列作为第一气象分析场序列,其之后的预报时长内(如4月10日00点00分到4月10日12点00分)的气象分析场序列为第二分析场序列。




图 6-4 训练过程的各时间点和时间段在时间轴上的相对位置示意图

(3) 步骤 1-3: 将所述第一气象分析场序列和第二气象分析场序列作为深度学习神经网络的输入和输出,对深度学习神经网络进行训练。

获取多个第一气象分析场序列和对应的第二气象分析场序列,根据上述训练方法对所述深度学习神经网络进行重复训练。

具体地,在将所述第一气象分析场序列输入输入层、第二气象分析场序列输入输出层之后,还包括以下步骤:

首先,在所述第一气象分析场序列中选取预设层数数量的气象分析

场。在步骤 S1-1 中, 初始化一个具有预设层数中间层的深度学习神经网络, 本步骤中, 从所述第一气象分析场序列中选取该预设层数数量的气象分析场, 获取所述预设层数个气象分析场对应的时间点, 将所述时间点中离当前时刻最远的第 k 个时间点之后的预报时长内的气象分析场序列输入所述第一深度学习神经网络的第 k 个中间层, 其中, k 是从 1 到预设层数的自然数。

为控制深度学习神经网络完成训练, 获取当前时刻(如 4 月 11 日 12 点 00 分)预报时长之前(例如, 预报时长为 12 小时, 12 小时之前是 4 月 11 日 00 点 00 分之前)最近的符合预设条件的设定时长(如 4 月 10 日 23 点 00 分到 4 月 11 日 00 点 00 分)内的第三气象分析场序列及紧随的预报时长内(如 4 月 11 日 00 点 00 分到 4 月 11 日 12 点 00 分)的第四气象分析场序列。

所述深度学习神经网络完成训练的条件为: 将第三气象分析场序列输入深度学习神经网络, 获得的输出结果与对应的第四气象分析场序列之间的对比误差不大于停止阈值。深度学习神经网络在进行训练的同时, 也可以用历史数据进行预测, 并将预测的结果与已有的历史数据比较, 如果预测结果与历史数据非常接近, 则说明深度学习神经网络训练完成, 可以将其用于预报。

具体地, 用于训练的数据存储在历史气象大数据中。气象分析场序列均由服务器中预存的气象分析场中查找获取。其中, 气象分析场通过大数据进行存储和获取, 也就是说, 采集任意时间任意预报区域的气象分析场存入大数据, 从大数据中可获取任意时间任意预报区域的气象分析场。

具体地, 建立气象分析场的 HBase 大数据库表, 并将采集到的气象分析场及其对应时间存入气象分析场的 HBase 中, 同时可以根据气象分析场的时间, 从气象分析场的 HBase 大数据库表中获取对应时间的气象分析场。

(4) 步骤 S1-4: 将训练得到的深度学习神经网络, 作为所述预报区域的深度学习神经网络。

2. 步骤 S2

如图 6-5 所示，步骤 S2 包括：

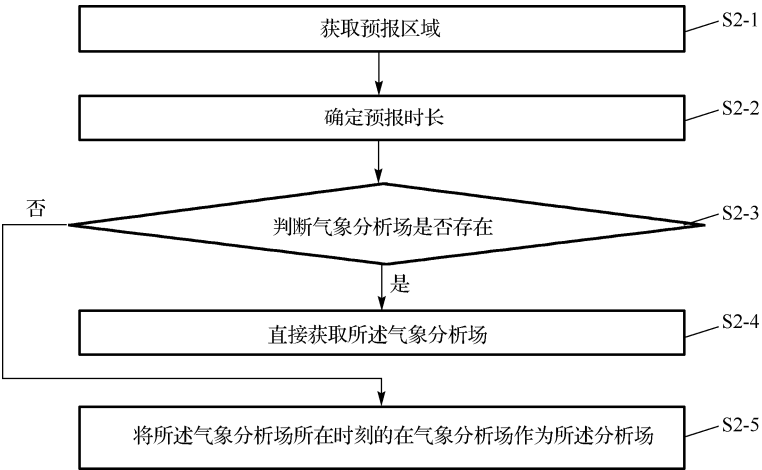


图 6-5 步骤 S2 的流程图

- (1) 步骤 S2-1：获取预报区域。预报区域可以由用户指定。确定预报区域的意义还在于选择对应的深度学习神经网络和输入相应的气象分析场序列。
- (2) 步骤 S2-2：确定预报时长。预报时长可以由用户指定。预报时长可以包括未来 12 小时、24 小时、48 小时及 72 小时等。
- (3) 步骤 S2-3：判断气象分析场是否存在。若所述气象分析场存在，则执行步骤 S2-4，否则执行步骤 S2-5。
- (4) 步骤 S2-4：直接获取所述气象分析场。
- (5) 步骤 S2-5：将所述气象分析场所在时刻的在气象分析场作为所述分析场。实况资料的站点分布不均匀，在气象分析场经过插值后，是均匀分布的。在气象分析场在气象预报领域的含义也是所属领域的技术人员所熟知的。

6.1.3 基于大数据与深度学习的气象预报系统

如图 6-6 所示，为一种技术方案的气象预报系统模块图。该气象预报系统包括分析场获取模块 1、预报模块 2、深度学习神经网络 3、训练模块 4、历史气象大数据 5。

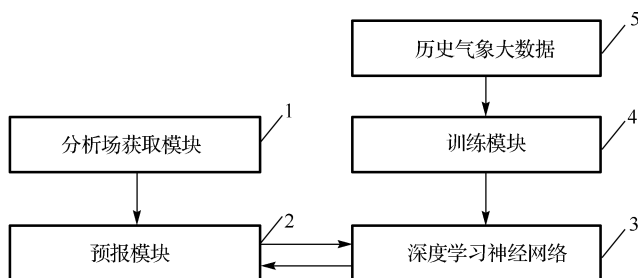


图 6-6 气象预报系统模块图

分析场获取模块 1，用于获取预报区域的最近设定时长内的气象分析场序列。

如图 6-7 所示，分析场获取模块 1 包括预报区域选择单元 1-1、预报时长确定单元 1-2 及分析场生成单元 1-3。




图 6-7 分析场获取模块 1 的模块图

- ① 预报区域选择单元 1-1，用于获取预报区域。
- ② 预报时长确定单元 1-2，用于确定预报时长。
- ③ 分析场生成单元 1-3，用于若所述气象分析场存在，则直接获取

所述气象分析场，否则，将所述气象分析场所在时刻的在气象分析场作为所述分析场。

预报模块 2，用于将所述最近气象分析场序列输入所述预报区域的深度学习神经网络进行学习，得到所述预报区域的深度学习神经网络的输出。深度学习神经网络特指预报区域的深度学习神经网络。其以该预报区域的气象分析场序列为输入，根据输入得到深度学习神经网络的输出。

该气象预报系统还可以包括对所述预报区域的深度学习神经网络 3 和训练模块 4。如图 6-8 所示，所述训练模块 4 包括初始化单元 4-1、气象分析场获取单元 4-2 和训练控制单元 4-3。

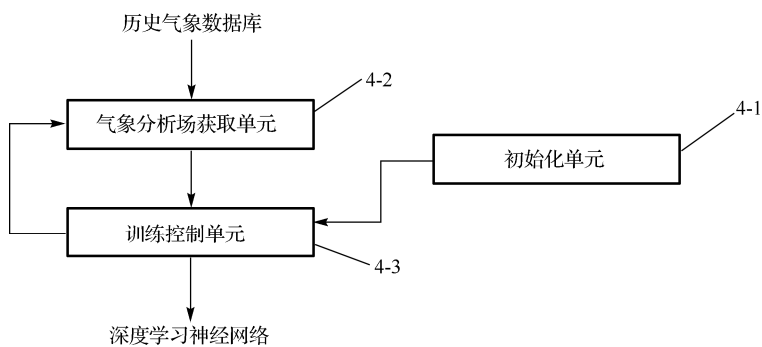


图 6-8 训练模块 4 的模块图

- ① 初始化单元 4-1，用于初始化一个具有输入层、预设层数个中间层及输出层的深度学习神经网络；所述预设层数小于设定时长内的气象分析场序列中的气象分析场的数量。
- ② 气象分析场获取单元 4-2，用于获取预报区域当前时刻预报时长之前的第一气象分析场序列和紧随所述第一气象分析场之后的预报时长内的第二气象分析场序列。其中，所述第一气象分析场序列为任一符合预设条件的设定时长内的气象分析场序列。

③ 训练控制单元 4-3, 用于将所述第一气象分析场序列和第二气象分析场序列作为深度学习神经网络的输入和输出, 对深度学习神经网络进行训练; 并获取多个第一气象分析场序列和对应的第二气象分析场序列, 对所述深度学习神经网络进行重复训练; 将训练完成的深度学习神经网络作为所述预报区域的深度学习神经网络。

该气象预报系统还可以包括历史气象大数据 5, 用于将训练的数据存储在历史气象大数据中。利用该模块可以进行气象预报, 提高预测的准确性。

6.2 基于大数据与深度学习的用户数据处理方法和系统

本节研究了一种用户数据处理方法, 具体包括: 获取待分析用户的用户数据, 所述用户数据包括面部图像数据和/或掌心图像数据; 将所述用户数据输入对应的已训练的第一预测深度学习神经网络, 第一预测深度学习神经网络的参数是将训练用户对应的训练用户大数据作为输入, 将与训练用户大数据对应的训练用户的用户状态标签作为预期输出, 输入第一预测深度学习模型训练得到, 其中所述训练用户大数据的数据类型与待分析用户的用户数据的数据类型匹配; 获取所述已训练的第一预测深度学习神经网络输出的对应的用户状态预测标签; 根据所述用户状态预测标签确定所述待分析用户的用户状态。此外, 本节还提出了一种用户数据处理系统。

6.2.1 研究现状

大数据在越来越多的领域得到了应用, 特别是在分析关联关系上有着独特的优势^[36-41]。在日常生活中可以发现, 用户的特征往往与自身的状态存在一定的统计关联关系, 现有的算法不能根据用户的数据对用户的状态进行准确的分析预测。

基于此,有必要针对上述技术问题,提出一种用户数据处理方法和系统。基于大数据与深度学习建立待分析用户的用户数据与状态标签的相关性,提供客观的分析依据,根据用户数据预测用户的状态。通过获取待分析用户的用户数据(用户数据包括面部图像数据和/或掌心图像数据),将用户数据输入对应的已训练的第一预测深度学习神经网络,第一预测深度学习神经网络的参数是将训练用户对应的训练用户大数据作为输入,将与所述训练用户大数据对应的训练用户的用户状态标签作为预期输出,输入第一预测深度学习模型训练得到的。其中,训练用户大数据的数据类型与待分析用户的用户数据的数据类型匹配,获取已训练的第一预测深度学习神经网络输出的对应的用户状态预测标签,根据用户状态预测标签确定所述待分析用户的用户状态,基于大数据与深度学习建立待分析用户的用户数据与状态标签的相关性,提供客观的分析依据。

6.2.2 基于大数据与深度学习的用户数据处理方法

1. 技术方案 1

如图 6-9 所示,在本技术方案中,提出了一种用户数据处理方法,具体包括以下步骤:

(1)步骤 S1-1: 获取待分析用户的用户数据,用户数据包括面部图像数据和/或掌心图像数据。

其中,用户数据是携带了用户特征的数据,如面部图像数据是指表征面部图像特征的数据,掌心图像数据是指表征掌心图像特征的数据,可以是拍摄的照片,也可以是对照片进行图像特征提取后的图像用户数据。待分析用户的用户数据可以携带在终端发送的用户状态预测请求中,也可以是从服务器的数据库获取的用户数据。在本技术方案中,用户数据是从服务器存储的

注册用户对应的图像信息中提取的图像数据，随着注册用户信息更新。面部图像数据是通过在用户图像中提取人脸区域得到的，掌心图像数据是通过在用户图像中提取手掌内侧区域得到的。

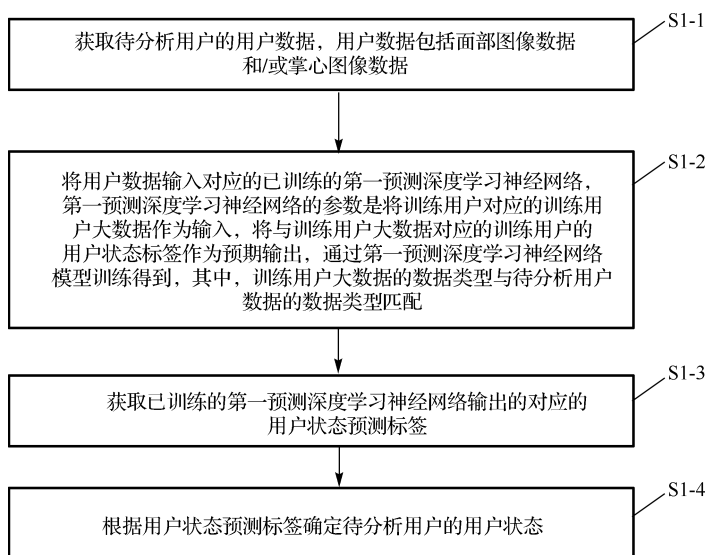


图 6-9 用户数据处理方法的流程图

面部图像数据包括人脸关键点，如眼睛、鼻子、嘴巴、眉毛、耳朵等。掌心图像数据包括手指、掌纹，如各个手指长度、健康纹、生命纹、感情纹、事业纹等。可以理解的是，如果是其他类别的用户数据，则可包括其他类别图像数据对应的关键区域。

(2) 步骤 S1-2: 将用户数据输入对应的已训练的第一预测深度学习神经网络，第一预测深度学习神经网络的参数是将训练用户对应的训练用户大数据作为输入，将与训练用户大数据对应的训练用户的用户状态标签作为预期输出，通过第一预测深度学习神经网络模型训练得到，其中，训练用户大数据的数据类型与待分析用户的用户数据的数据类型匹配。

其中，已训练的深度学习神经网络包括输入层、多个隐层和输出层。其中，层数、每层预设节点数、各网络连接的权值均由训练得到。

获取数据量足够大的训练用户对应的训练用户大数据作为第一预测深度学习神经网络的训练数据进行训练，得到第一预测深度学习神经网络的参数。用户状态标签用于表征用户所处的状态，可从用户的注册资料中获取，也可通过分析用户历史操作行为确定，如职业状态、财富状态、健康状态、易患病类型、性格等。用户状态标签可通过预设的规则生成，如将职业状态、财富状态、健康状态、易患病类型、性格依次作为用户状态标签的各个编码，各个编码占用预设位数，如每个编码占用一位，各个类型的状态分别对应不同的状态情况，各个状态情况对应不同的预设编码值。例如，职业状态分为工、农、商、学、兵，分别用数值 1、2、3、4、5 对应表示，作为用户状态标签的第 1 位编码；财富状态分为大贫、大富、小贫、小富，分别用数值 1、2、3、4 对应表示，判断的标准是，平均收入以下为小贫，平均收入以上为小富，平均收入 10 倍以上为大富，平均收入 1/10 以下为大贫，作为用户状态标签的第 2 位编码；健康状态分为极多病、多病、少病、极少病，用数值 1、2、3、4 对应表示，判断的标准是，每年生病时间超过 2 个月为极多病，超过 1 个月为多病，少于 1 个月为少病，少于 1 周为极少病，作为用户标签的第 3 位编码；易患病类型分为心脏病、肺病、肝病，用数值 1、2、3 对应表示，作为用户标签的第 4 位编码；性格状态分为外向、内向、不确定，用数值 1、2、3 对应表示，作为用户标签的第 5 位编码。

其中，训练用户大数据的数据类型与待分析用户的用户数据的数据类型匹配是指，预先可获取不同类型的输入数据作为训练用户大数据，得到可接受不同数据类型输入的不同的预测深度学习神经网络。从而根据用户数据的数据类型，从候选预测深度学习神经网络中获取输入数据类型与用户数据的

数据类型一致的预测深度学习神经网络，作为目标预测深度学习神经网络。若待分析用户的用户数据是图像数据，则获取输入数据为图片的预测深度学习神经网络，得到第一预测深度学习神经网络；若待分析用户的用户数据是特征字符数据，则获取输入数据为特征字符数据的预测深度学习神经网络，得到第一预测深度学习神经网络。

在本技术方案中，训练用户大数据除包括面部图像大数据和/或掌心图像大数据外，还可以包括用户的地域、年龄信息大数据，形成多维度的输入训练数据进行训练。可针对不同地区、不同年龄，生成对应的不同的已训练的深度学习神经网络，提高不同地区、不同年龄的用户在预测时的适应度与准确性。

由于用户数据与用户状态标签存在关联关系，形成客观的科学依据大数据进行分析，能够提高用户状态预测的客观依据性。

(3)步骤 S1-3：获取已训练的第一预测深度学习神经网络输出的对应的用户状态预测标签。

具体地，深度学习神经网络输出的用户状态预测标签结果的形式不限，可以是预设格式的标签，用户状态预测标签中各个不同类型状态的编码位置与数值含义和训练时的训练用户的用户状态标签保持一致。已训练的第一预测深度学习神经网络可以根据输入的待分析用户的用户数据分析，输出对应的客观的用户状态预测标签。

(4)步骤 S1-4：根据用户状态预测标签确定待分析用户的用户状态。

具体地，通过用户状态预测标签对应的预设规则，解析用户状态预测标签，得到各个不同类型的状态对应的状态值，从而根据状态值对应的状态内容确定待分析用户的用户状态。如用户状态预测标签为“41223”，对应的预测用户状态为“职业：学；财富：大贫；健康：多病；易患病类型：肺病；性格：不确定”。

2. 技术方案 2

如图 6-10 所示，在本技术方案中，包括以下步骤：

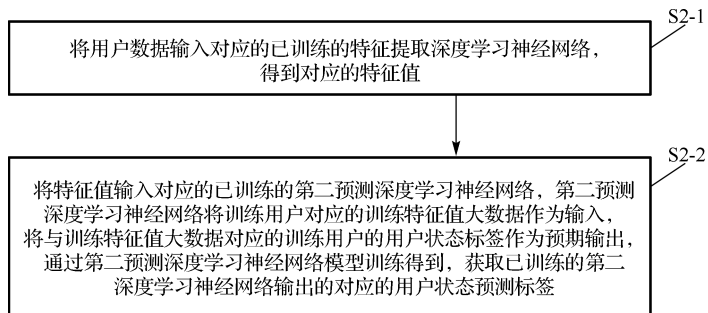


图 6-10 确定用户状态预测标签的流程图

(1) 步骤 S2-1：将用户数据输入对应的已训练的特征提取深度学习神经网络，得到对应的特征值。

具体地，特征提取深度学习神经网络用于根据输入数据提取相应的特征，得到特征值。已训练的特征提取深度学习神经网络是将训练用户对应的训练用户大数据作为输入，将与训练用户大数据对应的训练用户的用户特征作为预期输出，通过特征提取深度学习神经网络模型训练得到。其中，训练用户大数据包括面部图像大数据和/或掌心图像大数据。

在本技术方案中，将训练用户大数据作为特征提取深度学习神经网络模型的输入，对特征提取深度学习神经网络模型进行无监督训练，将训练用户大数据作为特征提取深度学习神经网络模型的输入，将所述训练用户大数据对应的训练用户的用户特征作为预期输出，再对特征提取深度学习神经网络模型进行有监督训练，得到已训练的特征提取深度学习神经网络。

其中，用户特征是根据特征提取算法从训练用户大数据中提取的特征。用户特征可包括多个维度不同类型的特征，如对于掌心特征，可包括手指长度特征、健康纹特征、太阳纹特征等，对于每个类型的特征又存

在不同的特征值。可根据预设规则将各个不同类型特征的特征值按照预设顺序排列，形成最终的特征值。特征值可以是数字、字符等，可自定义其含义。

例如，对于健康纹特征，取值 1 代表从小指下面向生命纹走，取值 2 代表健康纹断断续续，取值 5 代表有链状；取值 4 代表有岛纹，将健康纹特征作为手相特征的第 1 位编码；对于太阳线特征，取值 1 代表太阳纹成双线，取值 2 代表太阳纹过多，取值 3 代表太阳纹有岛纹或像十字形，将太阳线特征作为手相特征的第 2 位编码；对于无名指与食指长度特征，取值 1 代表无名指长，取值 2 代表食指长，取值 3 代表无名指比食指长。取值 4 代表食指比无名指长，将无名指与食指长度特征作为手相特征的第 3 位编码。

不同的训练用户对应的用户图像对应不同的用户特征，可通过图像标识不同的手图像，并得到对应的掌心特征，形成第一特征大数据，例如：

手图像 10，231；

手图像 12，321；

手图像 31，111；

.....

在训练时，可根据第一特征大数据得到特征提取深度学习神经网络模型的输入数据和对应的预期输出数据，从而方便地进行训练。

(2) 步骤 S2-2：将特征值输入对应的已训练的第二预测深度学习神经网络，第二预测深度学习神经网络将训练用户对应的训练特征值大数据作为输入，将与训练特征值大数据对应的训练用户的用户状态标签作为预期输出，通过第二预测深度学习神经网络模型训练得到，获取已训练的第二深度学习神经网络输出的对应的用户状态预测标签。

具体地，特征值用于表征用户的特征，与用户图像数据相比，更准确、

直接，第二预测深度学习神经网络的输入是特征值，输出是对应的用户状态预测标签。

已训练的第二预测深度学习神经网络包括输入层、多个隐层和输出层，其中，层数、每层预设节点数、各网络连接的权值由训练得到。

获取数据量足够大的训练用户对应的训练特征值大数据作为第二预测深度学习神经网络的训练数据进行训练，得到第二预测深度学习神经网络的参数。用户状态标签可采用与技术方案 1 中相同的方法获取。

在本技术方案中，用户特征与用户状态标签存在关联关系，可形成客观的科学依据大数据进行分析，提高用户状态预测的客观依据性。且特征值比用户图像数据占用的存储空间小，对于需要经过网络传输的场景，可减小带宽，减少训练数据占用的存储空间，提高空间利用率。

在本技术方案中，通过采集或互联网挖掘形成第二特征大数据，第二特征大数据由 3 个维度的数据组成，包括手图像、掌心特征、用户状态标签，例如：

手图像 10, 231, 43233;

手图像 31, 111, 12311;

.....

第二特征大数据中包括了手图像、掌心特征、用户状态标签的对应关系，可用于快速形成特征提取深度学习神经网络模型和第二预测深度学习神经网络模型的输入数据和预期输出，从而提高了模型训练的效率。

3. 技术方案 3

如图 6-11 所示，在本技术方案中，方法包括以下步骤：

(1) 步骤 S3-1：获取待分析用户的用户属性信息。

具体地，用户属性是指用户本身的信息，包括用户性别、年龄等，因为

用户的特征数据与性别、年龄相关，所以需要考虑用户属性，从而使预测更为接近真实。可通过自定义规则表达用户属性，如将用户性别“女”用 0 表示，“男”用 1 表示，作为用户属性的第 1 位编码，将用户年龄作为用户属性的第 2~4 位编码。

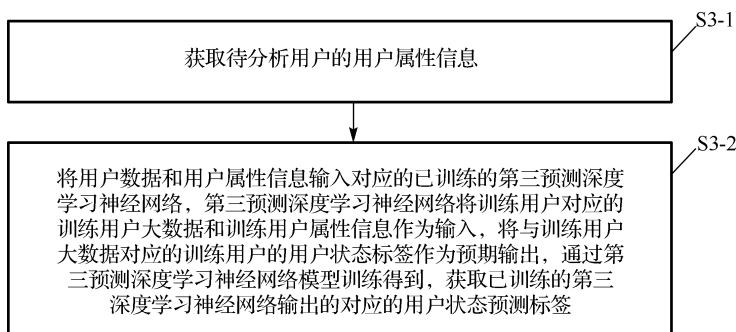


图 6-11 确定用户状态预测标签的流程图

(2) 步骤 S3-2：将用户数据和用户属性信息输入对应的已训练的第三预测深度学习神经网络，第三预测深度学习神经网络将训练用户对应的训练用户大数据和训练用户属性信息作为输入，将与训练用户大数据对应的训练用户的用户状态标签作为预期输出，通过第三预测深度学习神经网络模型训练得到，获取已训练的第三深度学习神经网络输出的对应的用户状态预测标签。

具体地，已训练的第三预测深度学习神经网络包括输入层、多个隐层和输出层，其中，层数、每层预设节点数、各网络连接的权值由训练得到。

获取数据量足够大的训练用户对应的训练用户大数据和训练用户属性信息作为第三预测深度学习神经网络的训练数据进行训练，得到第三预测深度学习神经网络的参数。用户状态标签可采用与技术方案 1 相同的方法获取。

在本技术方案中，在用户图像数据的基础上，还考虑了用户属性信息，形成客观的科学依据大数据进行分析，进一步提高了用户状态预测的客观依据性，使预测更为准确，与用户属性相匹配。

在本技术方案中，不同的训练用户对应的用户图像对应不同的用户属性信息，通过图像标识不同的手图像，并得到对应的用户属性信息，形成第三特征大数据，例如：

手图像 10，1020；
手图像 31，0013；
.....

第三特征大数据中包括手图像、用户属性信息的对应关系，可用于快速形成第三预测深度学习神经网络模型的输入数据，从而提高模型训练的效率。

4. 技术方案 4

如图 6-12 所示，在本技术方案中，方法包括以下步骤：

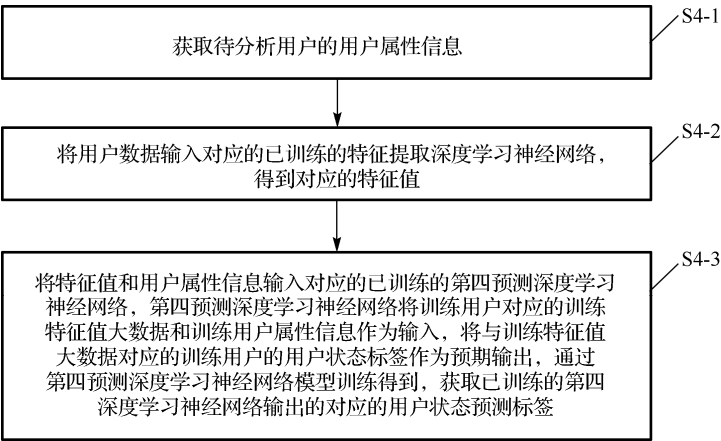


图 6-12 确定用户状态预测标签的流程图

(1) 步骤 S4-1：获取待分析用户的用户属性信息。

(2) 步骤 S4-2: 将用户数据输入对应的已训练的特征提取深度学习神经网络, 得到对应的特征值。

具体地, 特征提取深度学习神经网络用于根据输入数据提取相应的特征, 得到特征值。已训练的特征提取深度学习神经网络将训练用户对应的训练用户大数据作为输入, 将与训练用户大数据对应的训练用户的用户特征作为预期输出, 通过特征提取深度学习模型训练得到。其中, 训练用户大数据包括面部图像大数据和/或掌心图像大数据。特征值用于表征用户的特征, 与用户图像数据相比, 更准确直接。

(3) 步骤 S4-3: 将特征值和用户属性信息输入对应的已训练的第四预测深度学习神经网络, 第四预测深度学习神经网络将训练用户对应的训练特征值大数据和训练用户属性信息作为输入, 将与训练特征值大数据对应的训练用户的用户状态标签作为预期输出, 通过第四预测深度学习模型训练得到, 获取已训练的第四深度学习神经网络输出的对应的用户状态预测标签。

具体地, 已训练的第四预测深度学习神经网络包括输入层、多个隐层和输出层, 其中, 层数、每层预设节点数、各网络连接的权值由训练得到。

获取数据量足够大的训练用户对应的训练特征值和训练用户属性信息作为第四预测深度学习神经网络的训练数据进行训练, 得到第四预测深度学习神经网络的参数。用户状态标签可采用与技术方案 1 中相同的方法获取。

在本技术方案中, 在特征值的基础上, 还考虑了用户属性信息, 形成客观的科学依据大数据进行分析, 进一步提高了用户状态预测的客观依据性, 使预测更为准确, 与用户属性相匹配。

在本技术方案中, 不同的训练用户对应的用户图像对应不同的用户属性信息, 通过图像标识不同的手图像, 得到对应的特征值和用户属性信息, 形成第四特征大数据, 例如:

手图像 10, 231, 1020;
手图像 31, 111, 0013;
.....

第四特征大数据中包括手图像、特征值、用户属性信息的对应关系，可用于快速形成第四预测深度学习神经网络模型的输入数据，从而提高模型训练的效率。

在本技术方案中，不同的训练用户对应的用户图像对应不同的用户属性信息，通过图像标识不同的手图像，得到对应的特征值、用户属性信息和用户状态标签，形成第五特征大数据，例如：

手图像 10, 231, 1020, 43233;
手图像 31, 111, 0013, 12311;
.....

第五特征大数据中包括手图像、特征值、用户属性信息、用户状态标签的对应关系，可用于快速形成第四预测深度学习神经网络模型的输入数据和预期输出数据，从而提高模型训练的效率。

5. 技术方案 5

如图 6-13 所示，在本技术方案中，方法包括以下步骤：




图 6-13 输出显示的流程图

(1) 步骤 S5-1：获取用户状态预测标签对应的用户状态预测内容信息，将用户状态预测内容信息输出并显示。

具体地，例如，将用户状态预测标签 Y1 (41223) 转换为用户状态预测内

容信息 Y2(职业: 学; 财富: 大贫; 健康: 多病; 易患病类型: 肺病; 性格: 不确定), 将用户状态预测内容信息输出并显示, 便于用户直观了解用户状态预测内容。

(2) 步骤 S5-2: 获取特征值对应的用户特征内容信息, 将用户特征内容信息输出并显示。

具体地, 根据特征值对应的特征输出用户特征内容信息, 如掌心特征值为“231”时, 就代表健康纹断断续续、太阳纹有岛纹或像十字形、无名指比食指长, 将用户特征内容信息输出并显示, 便于用户直观了解用户特征。

6. 技术方案 6

如图 6-14 所示, 在本技术方案中, 步骤 S1-1 之前, 还包括以下步骤:

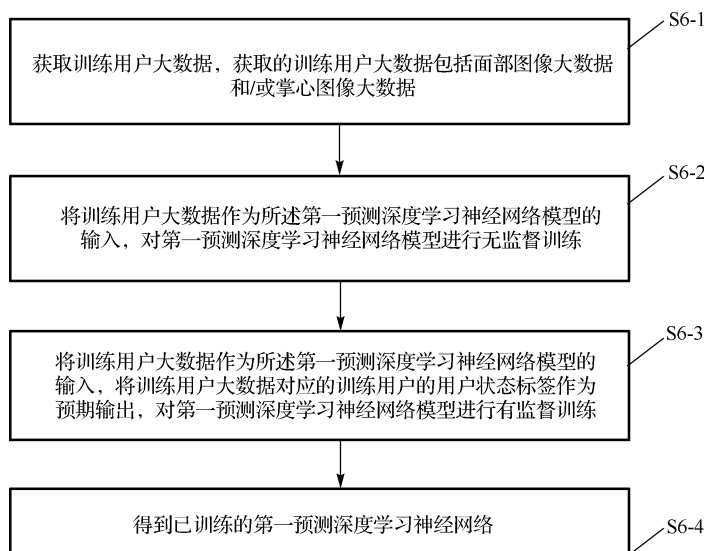


图 6-14 训练第一预测深度学习神经网络的流程图

(1) 步骤 S6-1: 获取训练用户大数据, 获取的训练用户大数据包括面部图像大数据和/或掌心图像大数据。

具体地,面部图像大数据和/或掌心图像大数据对应的训练用户可以相同或不同。训练用户可以是不同地域、不同年龄的用户,也可以根据地域或年龄,选取相同地域、相同年龄的用户数据作为训练用户大数据。

(2)步骤 S6-2: 将训练用户大数据作为所述第一预测深度学习神经网络模型的输入,对第一预测深度学习神经网络模型进行无监督训练。

具体地,初始化深度学习神经网络模型,使深度学习神经网络模型的输入层能接收的数据格式为图像,输出层的数据格式为用户状态标签,将该深度学习神经网络模型作为基于图像的第一预测深度学习神经网络模型。将训练用户大数据,如各掌心图像或面部图像输入第一预测深度学习神经网络模型,进行无监督训练。

(3)步骤 S6-3: 将训练用户大数据作为所述第一预测深度学习神经网络模型的输入,将训练用户大数据对应的训练用户的用户状态标签作为预期输出,对第一预测深度学习神经网络模型进行有监督训练。

具体地,可进行自顶向下的监督训练,这一步是在第一步学习获得各层参数的基础上,在最顶层的编码层添加一个分类器,如罗杰斯特回归、SVM等,然后通过带标签数据的监督训练,利用梯度下降法微调整个网络参数。

深度学习方法的第一步实质上是一个网络参数初始化过程,区别于传统深度学习方法的初值随机初始化,本技术方案中的初值是通过无监督训练输入数据的结构得到的,因而这个更接近全局最优,从而能够取得更好的效果。

(4)步骤 S6-4: 得到已训练的第一预测深度学习神经网络。

具体地,经过上面的无监督训练和有监督训练后,得到已训练的第一预测深度学习神经网络。

7. 技术方案 7

如图 6-15 所示,在本技术方案中,在步骤 S1-1 之前,还包括以下步骤:

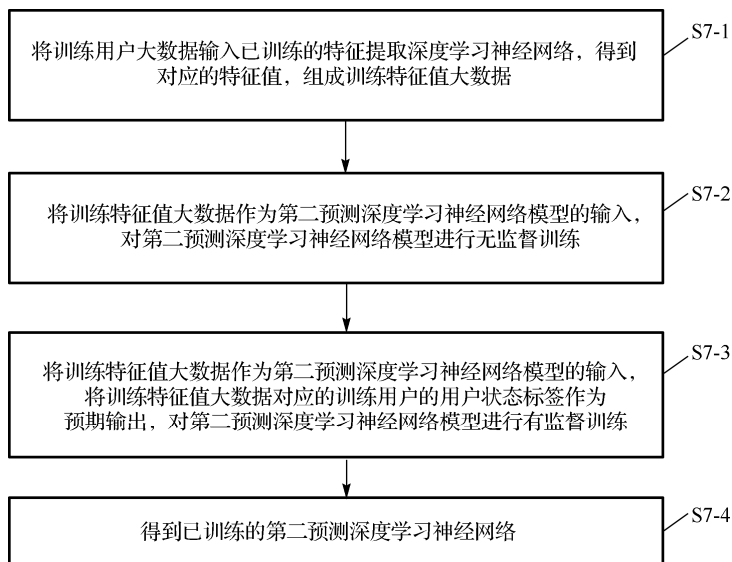


图 6-15 训练第二预测深度学习神经网络的流程图

(1) 步骤 S7-1：将训练用户大数据输入已训练的特征提取深度学习神经网络，得到对应的特征值，组成训练特征值大数据。

具体地，训练特征值大数据可由将图像数据输入已训练的特征提取深度学习神经网络，进行特征提取得到，在本技术方案中，训练特征值大数据也可以为用户直接输入预设的训练特征值。

(2) 步骤 S7-2：将训练特征值大数据作为第二预测深度学习神经网络模型的输入，对第二预测深度学习神经网络模型进行无监督训练。

具体地，初始化深度学习神经网络模型，使深度学习神经网络模型能接收的输入层数据格式为特征值，输出层的数据格式为用户状态标签，将该深度学习神经网络模型作为基于图像的第二预测深度学习神经网络模型。无监督训练的训练方式可采用前面技术方案中所述的方式，不再赘述。

(3) 步骤 S7-3：将训练特征值大数据作为第二预测深度学习神经网络模型的输入，将训练特征值大数据对应的训练用户的用户状态标签作为预期输出，对第二预测深度学习神经网络模型进行有监督训练。

出，对第二预测深度学习神经网络模型进行有监督训练。

具体地，由于训练特征值大数据比原始图像占用空间小，从而可节省训练数据的存储空间。在需要进行网络传输训练数据时，也可以节省带宽。

(4) 步骤 S7-4：得到已训练的第二预测深度学习神经网络。

具体地，经过上面的无监督训练和有监督训练，得到已训练的第二预测深度学习神经网络。

8. 技术方案 8

如图 6-16 所示，在本技术方案中，在步骤 S1-1 之前还包括以下步骤：

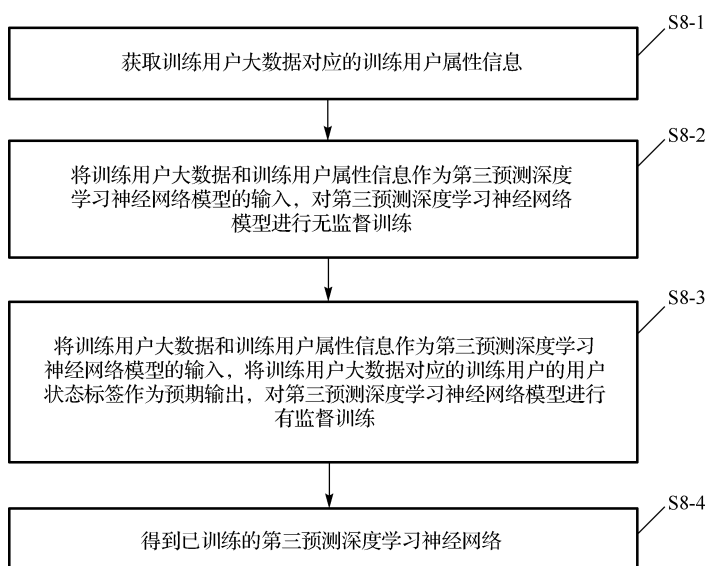


图 6-16 训练第三预测深度学习神经网络的流程图

(1) 步骤 S8-1：获取训练用户大数据对应的训练用户属性信息。

具体地，获取训练用户大数据对应各个训练用户对应的训练用户属性信息。

(2) 步骤 S8-2：将训练用户大数据和训练用户属性信息作为第三预测深

深度学习神经网络模型的输入,对第三预测深度学习神经网络模型进行无监督训练。

具体地,初始化深度学习神经网络,使该深度学习神经网络能接收的输入层数据格式为图像、用户属性,输出层的数据格式为用户状态标签,将该深度学习神经网络作为基于图像和用户属性的第三预测深度学习神经网络模型。无监督训练的训练方式可采用前面技术方案中所述的方式,不再赘述。

(3)步骤 S8-3:将训练用户大数据和训练用户属性信息作为第三预测深度学习神经网络模型的输入,将训练用户大数据对应的训练用户的用户状态标签作为预期输出,对第三预测深度学习神经网络模型进行有监督训练。

具体地,用户状态受到训练用户属性信息的影响,在进行训练时同时考虑训练用户属性信息,可使训练出的第三预测深度学习神经网络的预测结果更准确。

(4)步骤 S8-4:得到已训练的第三预测深度学习神经网络。

具体地,经过上面的无监督训练和有监督训练后,得到已训练的第三预测深度学习神经网络。

9. 技术方案 9

如图 6-17 所示,在本技术方案中,在步骤 S1-1 之前,还包括以下步骤:

(1)步骤 S9-1:将训练特征值大数据和训练用户属性信息作为第四预测深度学习神经网络模型的输入,对第四预测深度学习神经网络模型进行无监督训练。

具体地,初始化深度学习神经网络,使该深度学习神经网络能接收的输入层数据格式为特征值、用户属性,输出层的数据格式为用户状态标签,将

该深度学习神经网络作为基于特征值和用户属性的第四预测深度学习神经网络模型。无监督训练的训练方式可采用前面技术方案中所述的方式，不再赘述。

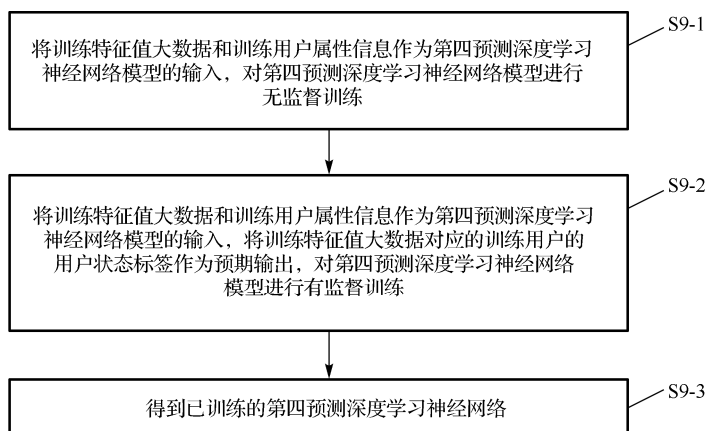


图 6-17 训练第四预测深度学习神经网络的流程图

(2) 步骤 S9-2: 将训练特征值大数据和训练用户属性信息作为第四预测深度学习神经网络模型的输入，将训练特征值大数据对应的训练用户的用户状态标签作为预期输出，对第四预测深度学习神经网络模型进行有监督训练。

具体地，将训练特征值大数据和训练用户属性信息作为输入，特征值占用空间小，且由于用户状态受到训练用户属性信息的影响，在进行训练时同时考虑训练用户属性信息，可使训练出的第四预测深度学习神经网络能接收的预测结果更准确，且训练过程占用存储空间小。对第四预测深度学习神经网络模型进行有监督训练。

(3) 步骤 S9-3: 得到已训练的第四预测深度学习神经网络。

具体地，经过上面的无监督训练和有监督训练后，得到已训练的第四预测深度学习神经网络。

6.2.3 基于大数据与深度学习的用户数据处理系统

1. 技术方案 1

在本技术方案中，如图 6-18 所示，提供了一种用户数据处理系统，包括以下模块：

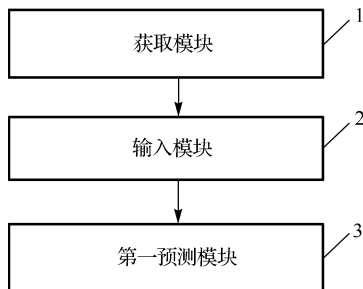


图 6-18 用户数据处理系统的结构图

(1) 获取模块 1，用于获取待分析用户的用户数据，所述用户数据包括面部图像数据和/或掌心图像数据。

(2) 输入模块 2，用于将用户数据输入对应的已训练的第一预测深度学习神经网络，第一预测深度学习神经网络将训练用户对应的训练用户大数据作为输入，将与训练用户大数据对应的训练用户的用户状态标签作为预期输出，通过第一预测深度学习神经网络模型训练得到，其中，训练用户大数据的数据类型与待分析用户的用户数据的数据类型相匹配。

(3) 第一预测模块 3，用于获取已训练的第一预测深度学习神经网络输出的对应的用户状态预测标签，根据用户状态预测标签确定待分析用户的用户状态。

2. 技术方案 2

在本技术方案中，如图 6-19 所示，系统还包括：

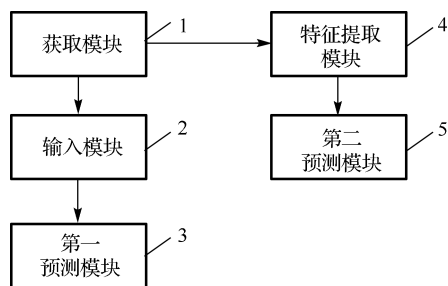


图 6-19 用户数据处理系统的结构图

(1) 特征提取模块 4, 用于将用户数据输入对应的已训练的特征提取深度学习神经网络, 得到对应的特征值。

(2) 第二预测模块 5, 用于将特征值输入对应的已训练的第二预测深度学习神经网络, 第二预测深度学习神经网络将训练用户对应的训练特征值大数据作为输入, 将与训练特征值大数据对应的训练用户的用户状态标签作为预期输出, 通过第二预测深度学习神经网络模型训练得到, 获取已训练的第二深度学习神经网络输出的对应的用户状态预测标签。

3. 技术方案 3

在本技术方案中, 如图 6-20 所示, 获取模块 1 还用于获取待分析用户的用户属性信息。

系统还包括:

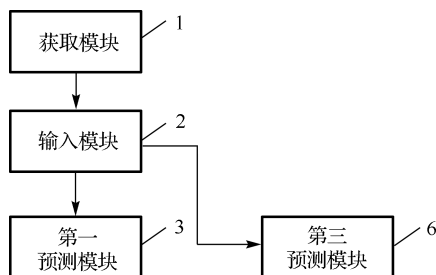


图 6-20 用户数据处理系统的结构图

第三预测模块 6，用于将用户数据和用户属性信息输入对应的已训练的第三预测深度学习神经网络，第三预测深度学习神经网络将训练用户对应的训练用户大数据和训练用户属性信息作为输入，将与训练用户大数据对应的训练用户的用户状态标签作为预期输出，通过第三预测深度学习神经网络模型训练得到，获取已训练的第三深度学习神经网络输出的对应的用户状态预测标签。

4. 技术方案 4

在本技术方案中，如图 6-21 所示，获取模块 1 还用于获取待分析用户的用户属性信息。

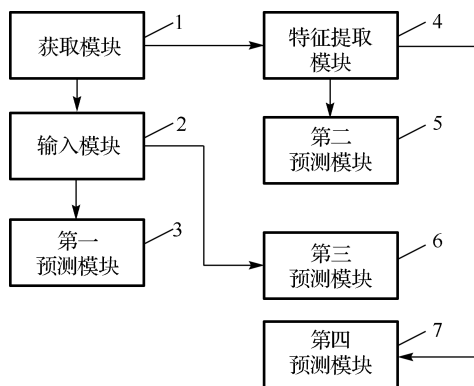


图 6-21 用户数据处理系统的结构图

系统还包括：

(1) 特征提取模块 4，用于将用户数据输入对应的已训练的特征提取深度学习神经网络，得到对应的特征值。

(2) 第四预测模块 7，用于将特征值和用户属性信息输入对应的已训练的第四预测深度学习神经网络，第四预测深度学习神经网络将训练用户对应的

训练特征值大数据和训练用户属性信息作为输入，将与训练特征值大数据对应的训练用户的用户状态标签作为预期输出，通过第四预测深度学习神经网络模型训练得到，获取已训练的第四深度学习神经网络输出的对应的用户状态预测标签。

5. 技术方案 5

在本技术方案中，如图 6-22 所示，系统还包括：

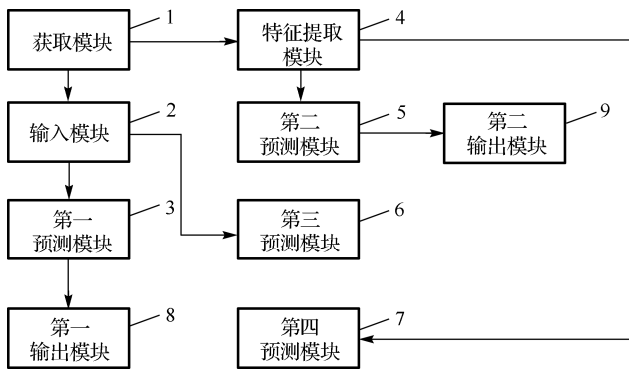


图 6-22 用户数据处理系统的结构图

- (1)第一输出模块 8,用于获取用户状态预测标签对应的用户状态预测内容信息，将用户状态预测内容信息输出并显示。
- (2)第二输出模块 9,用于获取特征值对应的用户特征内容信息，将用户特征内容信息输出并显示。

6. 技术方案 6

在本技术方案中，如图 6-23 所示，系统还包括：

第一训练模块 10,用于获取训练用户大数据，获取训练用户大数据包括面部图像大数据和/或掌心图像大数据，将训练用户大数据作为第一预测深度学习神经网络模型的输入，对第一预测深度学习神经网络模型进行无监督

训练,将训练用户大数据作为第一预测深度学习神经网络模型的输入,将训练用户大数据对应的训练用户的用户状态标签作为预期输出,对第一预测深度学习神经网络模型进行有监督训练,得到已训练的第一预测深度学习神经网络。

第二训练模块 11,用于将训练用户大数据输入已训练的特征提取深度学习神经网络,得到对应的特征值,组成训练特征值大数据,将训练特征值大数据作为第二预测深度学习神经网络模型的输入,对第二预测深度学习神经网络模型进行无监督训练,将训练特征值大数据作为第二预测深度学习神经网络模型的输入,将训练特征值大数据对应的训练用户的用户状态标签作为预期输出,对第二预测深度学习神经网络模型进行有监督训练,得到已训练的第二预测深度学习神经网络。

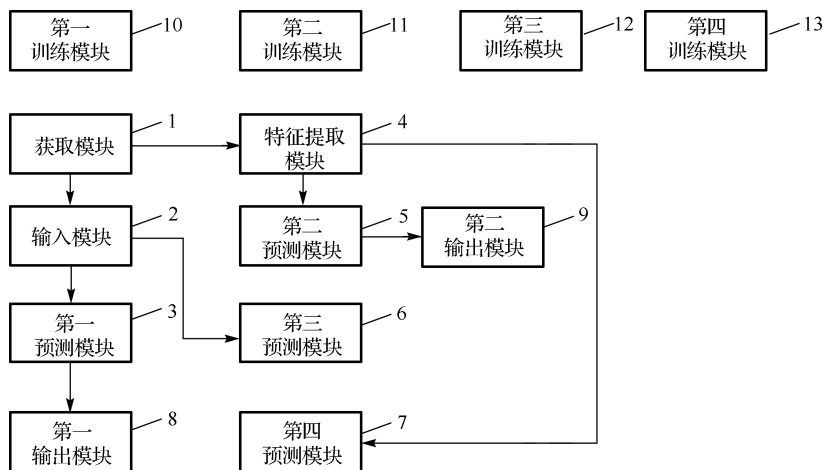


图 6-23 用户数据处理系统的结构图

第三训练模块 12,用于将训练用户大数据和训练用户属性信息作为第三预测深度学习神经网络模型的输入,对第三预测深度学习神经网络模型进行无监督训练;将训练用户大数据和所述训练用户属性信息作为第三预测深度

学习神经网络模型的输入，将训练用户大数据对应的训练用户的用户状态标签作为预期输出，对第三预测深度学习神经网络模型进行有监督训练；得到已训练的第三预测深度学习神经网络。

第四训练模块 13，用于将训练特征值大数据和训练用户属性信息作为第四预测深度学习神经网络模型的输入，对第四预测深度学习神经网络模型进行无监督训练，将训练特征值大数据和训练用户属性信息作为第四预测深度学习神经网络模型的输入，将训练特征值大数据对应的训练用户的用户状态标签作为预期输出，对第四预测深度学习神经网络模型进行有监督训练，得到已训练的第四预测深度学习神经网络。

结 束 语

深度学习技术之所以能够火起来，得益于大数据技术的发展，正是因为大数据技术，使海量数据的深度学习成为可能。同时，深度学习技术的发展，势必进一步促进大数据智能处理能力的提高。深度学习与大数据的共同作用是产生智能，为人类服务。

深度学习离不开大数据，因为如果没有海量的数据样本进行训练，深度学习无法获得很高的准确率，同时，如果没有大数据的处理能力，深度学习的层数就会受到限制而无法达到一定深度，从而无法实现深度学习的功能。

大数据离不开深度学习，因为大数据与小数据不同的是，大数据要挖掘的知识模式往往不明确，也就是说，难以用公式或者模型刻画，此时深度学习就有了用武之地，因为深度学习中可以蕴含极其复杂的、难以刻画的模型。

参 考 文 献

- [1] 杜伟男, 胡永利, 孙艳丰. 基于残差字典学习的图像超分辨率重建方法[J]. 北京工业大学学报, 2017, 43(1): 43-48.
- [2] 于康龙, 秦卫城, 杨进, 等. 超分辨率重建图像质量评价算法[J]. 计算机工程与应用, 2017, 53(2): 201-205.
- [3] 王义, 王江云, 安洁, 等. 基于奇异值分解的图像超分辨率重建[J]. 电子测量技术, 2017(3): 72-76.
- [4] 李亚鹏, 何斌. 采用 CCD 错位成像技术提高图像质量[J]. 光学学报, 2015(2): 116-123.
- [5] Priego G, Barrowman N J, Hurteau-Miller J, et al. Does 3T Fetal MRI Improve Image Resolution of Normal Brain Structures between 20 and 24 Weeks' Gestational Age?[J]. American Journal of Neuroradiology, 2017, 38(8): 1636-1642.
- [6] Tanzid M, Hogan N J, Sobhani A, et al. Absorption-induced Image Resolution Enhancement in Scattering Media[J]. ACS Photonics, 2016, 3(10): 1787-1793.
- [7] Croft L R, Goodwill P W, Konkle J J, et al. Low Drive Field Amplitude for Improved Image Resolution in Magnetic Particle Imaging[J]. Medical physics, 2016, 43(1): 424-435.
- [8] Li H, Yang X, Jian L, et al. A Sparse Representation-based Image Resolution Improvement Method by Processing Multiple Dictionary Pairs with Latent Dirichlet

- Allocation Model for Street View Images[J]. Sustainable Cities and Society, 2018, 38: 55-69.
- [9] Krah N, Testa M, Brons S, et al. An Advanced Image Processing Method to Improve the Spatial Resolution of Ion Radiographies[J]. Physics in Medicine & Biology, 2015, 60(21): 8525.
- [10] Chen Y, Xiao X, Liu H, et al. Dynamic Color Image Resolution Compensation Under Low Light[J]. Optik-International Journal for Light and Electron Optics, 2015, 126(6): 603-608.
- [11] 梁淑芬, 刘银华, 李立琛. 基于 LBP 和深度学习的非限制条件下人脸识别算法[J]. 通信学报, 2017, 35(6): 154-160.
- [12] 张雯, 王文伟. 基于局部二值模式和深度学习的人脸识别[J]. 计算机应用, 2015, 35(5): 1474-1478.
- [13] 李倩玉, 蒋建国, 齐美彬. 基于改进深层网络的人脸识别算法[J]. 电子学报, 2017, 45(3): 619-625.
- [14] 李小薪, 梁荣华. 有遮挡人脸识别综述: 从子空间回归到深度学习[J]. 计算机学报, 2018, 41(1): 177-207.
- [15] Ranjan R, Patel V M, Chellappa R. Hyperface: A Deep Multi-task Learning Framework for Face Detection, Landmark Localization, Pose Estimation, And Gender Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017.
- [16] Grm K, Štruc V, Artiges A, et al. Strengths and Weaknesses of Deep Learning Models for Face Recognition Against Image Degradations[J]. IET Biometrics, 2017, 7(1): 81-89.
- [17] Goswami G, Ratha N, Agarwal A, et al. Unravelling Robustness of Deep Learning Based Face Recognition Against Adversarial Attacks[J]. arXiv preprint arXiv: 1803.00401, 2018.

- [18] Zhang Y, Qiu M, Tsai C W, et al. Health-CPS: Healthcare Cyber-physical System Assisted by Cloud and Big Data[J]. IEEE Systems Journal, 2017, 11(1): 88-95.
- [19] Ponte S, Ferrara E, Dellepiane S, et al. Technical Concept of Health Data Collection and Integration Data Analysis for Gaining Meaningful Medical Information[M]. Clinical Rehabilitation Experience Utilizing Serious Games. Springer Vieweg, Wiesbaden, 2018: 105-129.
- [20] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展[J]. 计算机应用研究, 2014, 31(7): 1921-1930.
- [21] Goodfellow I, Bengio Y, Courville A, et al. Deep learning[M]. Cambridge: MIT press, 2016.
- [22] 易卓, 廖鹰, 胡晓峰, 等. 基于深度时空循环神经网络的协同作战行动识别[J]. 系统仿真学报, 2018, 30(3): 793-800.
- [23] Gregor K, Danihelka I, Graves A, et al. DRAW: A recurrent neural network for image generation[J]. arXiv preprint arXiv: 1502.04623, 2015.
- [24] Zhang D, Martinez N, Lindholm G, et al. Manage Sewer In-Line Storage Control Using Hydraulic Model and Recurrent Neural Network[J]. Water Resources Management, 2018, 32(6): 2079-2098.
- [25] Heffernan R, Yang Y, Paliwal K, et al. Capturing Non-local Interactions by Long Short-term Memory Bidirectional Recurrent Neural Networks for Improving Prediction of Protein Secondary Structure, Backbone Angles, Contact Numbers and Solvent Accessibility[J]. Bioinformatics, 2017, 33(18): 2842-2849.
- [26] Fei J, Lu C. Adaptive Sliding Mode Control of Dynamic Systems using Double Loop Recurrent Neural Network Structure[J]. IEEE transactions on neural networks and learning systems, 2018, 29(4): 1275-1286.

- [27] Wang J, Zhu X, Gong S, et al. Transferable Joint Attribute-Identity Deep Learning for Unsupervised Person Re-Identification[J]. arXiv preprint arXiv: 1803.09786, 2018.
- [28] Kuznetsov Y, Stücker J, Leibe B. Semi-supervised Deep Learning for Monocular Depth Map Prediction[C]. Proc. of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 6647-6655.
- [29] Narula S, Shameer K, Omar A M S, et al. Reply: Deep Learning with Unsupervised Feature in Echocardiographic Imaging[J]. Journal of the American College of Cardiology, 2017, 69(16): 2101-2102.
- [30] 陈立全, 卢苗, 胡爱群, 等. 基于二级定位的编码信道信息隐藏算法[J]. 通信学报, 2017, 34(12): 120-130.
- [31] 黄殿中, 张静飞, 张茹, 等. 基于大数据环境的多模态信息隐藏新体系[J]. 电子学报, 2017, 45(2): 477-484.
- [32] Cao Y, Zhou Z, Sun X, et al. Coverless Information Hiding Based on the Molecular Structure Images of Material[J]. Computers, Materials & Continua, 2018, 54(2): 197-207.
- [33] Parah S A, Sheikh J A, Ahad F, et al. Information Hiding in Medical Images: A Robust Medical Image Watermarking System for E-healthcare[J]. Multimedia Tools and Applications, 2017, 76(8): 10599-10633.
- [34] Katzenbeisser S, Petitcolas F. Information Hiding[M]. Artech house, 2016.
- [35] Tew Y, Wong K S. An Overview of Information Hiding in H. 264/AVC compressed video[J]. IEEE transactions on circuits and systems for video technology, 2014, 24(2): 305-319.
- [36] 黄勇军, 冯明, 丁圣勇, 等. 电信运营商大数据发展策略探讨[J]. 电信科学, 2017, 29(3): 7-11.

- [37] 周傲英, 钱卫宁, 王长波. 数据科学与工程: 大数据时代的新兴交叉学科[J]. 大数据, 2017, 1(2): 2015022.
- [38] Huda M, Maseleno A, Atmotiyoso P, et al. Big Data Emerging Technology: Insights into Innovative Environment for Online Learning Resources[J]. International Journal of Emerging Technologies in Learning (iJET), 2018, 13(1): 23-36.
- [39] Munevar S. Unlocking Big Data for Better Health[J]. Nature biotechnology, 2017, 35(7): 684.
- [40] Sookhak M, Gani A, Khan M K, et al. Dynamic Remote Data Auditing for Securing Big Data Storage in Cloud Computing[J]. Information Sciences, 2017, 380: 101-116.
- [41] He X, Ai Q, Qiu R C, et al. A Big Data Architecture Design for Smart Grids Based on Random Matrix Theory[J]. IEEE transactions on smart Grid, 2017, 8(2): 674-686.
- [42] 崔少泽, 王杜娟, 王苏桐, 等. 基于 GMM-RBF 神经网络的前列腺癌诊断方法[J]. 管理科学, 2018, 31(1): 33-47.
- [43] 惠瑞, 高小红, 田增民. 基于深度学习的 CT 脑影像分类方法用于阿尔茨海默病的初步筛查[J]. 中国医疗设备, 2017, 32(12): 15-19.
- [44] 田娟秀, 刘国才, 谷珊珊, 等. 医学图像分析深度学习研究方法研究与挑战[J]. 自动化学报, 2018, 44(3): 401-424.
- [45] 周航宁, 谢凤英, 姜志国, 等. 基于深度学习的皮肤影像分类[J]. 协和医学杂志, 2018, 9(1): 15-18.
- [46] 陈德华, 周东阳, 乐嘉锦. 基于深度学习的甲状腺结节良恶性预测方法研究[J]. 微型机与应用, 2017, 36(12): 13-15.
- [47] 陆家发, 张国明, 陈安琪. 基于深度学习的疾病诊断[J]. 医学信息学杂志, 2017, 38(4): 39-43.
- [48] Litjens G, Kooi T, Bejnordi B E, et al. A Survey on Deep Learning in Medical Image Analysis[J]. Medical image analysis, 2017, 42: 60-88.

- [49] Shen D, Wu G, Suk H I. Deep Learning in Medical Image Analysis[J]. Annual review of biomedical engineering, 2017, 19: 221-248.
- [50] Kermany D S, Goldbaum M, Cai W, et al. Identifying Medical Diagnoses and Treatable Diseases by Image-based Deep Learning[J]. Cell, 2018, 172(5): 1122-1131. e9.
- [51] Deep Learning for Medical Image Analysis[M]. Academic Press, 2017.
- [52] Cheng X, Zhang L, Zheng Y. Deep Similarity Learning for Multimodal Medical Images[J]. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization, 2018, 6(3): 248-252.
- [53] Kooi T, Litjens G, van Ginneken B, et al. Large Scale Deep Learning for Computer Aided Detection of Mammographic Lesions[J]. Medical image analysis, 2017, 35: 303-312.
- [54] 赖安伟, 王明欢, 陈晓霞, 等. 基于 SMS 的华中区域中尺度数值天气预报系统设计和实现[J]. 气象科技, 2017 (1): 51-57.
- [55] 许小峰. 从物理模型到智能分析——降低天气预报不确定性的新探索[J]. 气象, 2018, 44(3): 341-350.
- [56] 薛童, 管兆勇, 徐建军, 等. ATMS 和 CrIS 卫星资料同化对青藏高原天气预报的影响[J]. 高原气象, 2017, 36(4): 912-929.
- [57] Hatfield S, Subramanian A, Palmer T, et al. Improving Weather Forecast Skill through Reduced-Precision Data Assimilation[J]. Monthly Weather Review, 2018, 146(1): 49-62.
- [58] Thieblemont H, Haghighat F, Ooka R, et al. Predictive Control Strategies Based on Weather Forecast in Buildings with Energy Storage System: A Review of the State-of-the Art[J]. Energy and Buildings, 2017, 153: 485-500.
- [59] Gibney E. Space-weather Forecast to Improve with European Satellite[J]. Nature, 2017, 541(7637).

- [60] Kumpf A, Tost B, Baumgart M, et al. Visualizing Confidence in Cluster-based Ensemble Weather Forecast Analyses[J]. IEEE transactions on visualization and computer graphics, 2018, 24(1): 109-119.
- [61] Traore S, Luo Y, Fipps G. Gene-Expression Programming for Short-Term Forecasting of Daily Reference Evapotranspiration Using Public Weather Forecast Information[J]. Water Resources Management, 2017, 31(15): 4891-4908.